

Treball de Fi de Grau

**Grau en Enginyeria de Tecnologies Industrials**

**Estimació de la Producció i Consum d'energia  
solar emprant xarxes neuronals**

**MEMÒRIA**

**Autor:** Oriol Ruiz i Celada  
**Director:** Ramon Costa i Castelló  
**Convocatòria:** Juny 2019



Escola Tècnica Superior  
d'Enginyeria Industrial de Barcelona





## Resum

L'objectiu d'aquest treball consisteix en trobar un model que permeti realitzar la predicció tant de la producció d'energia solar com de la demanda elèctrica d'una instal·lació. Amb aquestes prediccions, els sistemes de control de la micro-xarxa podran realitzar una gestió més òptima de la instal·lació. Per a obtenir aquest model només es té accés a les mostres històriques, i el programa Matlab ha estat l'utilitzat per realitzar tots els càlculs necessaris.

Aquest model es basa amb xarxes neuronals. Les xarxes són un model computacional que pretén imitar el funcionament de les neurones biològiques, d'aquí prové el nom. Les xarxes consten de diverses neurones connectades entre sí, cada una amb uns pesos determinats. En introduir una sèrie d'entrades a la xarxa, dintre seu es realitzen una sèrie de càlculs fins a obtenir un resultat final. Per tal d'obtenir models precisos, cal entrenar la xarxa amb grans quantitats d'entrades. L'entrenament de les xarxes consisteix en introduir-li parelles de dades, per una banda les entrades i per l'altre el valor objectiu que hauria de sortir com a resultat de la xarxa. Mitjançant algorismes d'entrenament, es troben els pesos òptims que permeten ajustar al màxim els resultats de la xarxa als valors objectius. En el cas específic d'aquest treball, a les xarxes se li introduïen les mostres dels dos dies anteriors per tal de que la xarxa fes una predicció de les mostres del dia següent.

En aquesta memòria es fa una explicació del procediment realitzat fins a obtenir aquest model final. S'ha dividit el treball en etapes, cada una amb un objectiu i fonts de dades diferents. Degut a la naturalesa inherent de les xarxes neuronals, és necessari un procés d'experimentació i iteració per a desenvolupar-les. Al llarg de les etapes es va refinar els procediments d'obtenció de les xarxes, i es van definir uns criteris específics per tal de comparar xarxes entre elles. A l'última etapa, amb les lliçons apreses de les etapes inicials es crea el model final amb les dades provinents d'una instal·lació real que combina plaques solars i la demanda d'un grup d'habitatges. S'ha obtingut tant models separats per la producció i demanda, com un model conjunt que permet fer una predicció del dèficit.

Els models obtinguts permetien aconseguir aquestes prediccions amb diferents graus de precisió. Es comprova com la inclusió de factors addicionals al model, com informació relacionada amb el temps o la temperatura, ajudava a la millora de la precisió. Per contra, s'ha observat el detriment que suposa a la qualitat de les xarxes la manca de dades. El model final no és capaç d'adaptar-se del tot a les situacions amb més inestabilitat, però sí que permet predir les tendències que seguiran la producció i la demanda.



# Índex

Resum.....	3
Índex .....	5
1. Introducció.....	8
2. Antecedents del treball .....	9
2.1 Gestió de xarxes elèctriques.....	9
2.2 Energia solar.....	10
2.3 Xarxes neuronals.....	12
2.3.1 Context històric .....	12
2.3.2 Arquitectura d'una xarxa .....	14
2.3.3 Disseny de xarxes .....	15
2.3.4 Entrenament de les xarxes .....	16
2.3.5 Overfitting i Underfitting .....	20
3. Creació de la xarxa.....	21
3.1 Desenvolupament xarxes neuronals amb Matlab.....	21
3.1.1 Obtenció del codi base .....	21
3.1.2 Estructura del codi de creació de xarxes neuronals.....	22
3.2 Explicació procés de disseny iteratiu.....	24
3.2.1 Codificació de les proves.....	25
3.3 Fonts de les dades.....	25
3.3.1 Etapes 1 i 2. DKA Solar Center .....	25
3.3.2 Etapa 3. Càrrega energètica a Bèlgica.....	26
3.3.3 Etapa 4. Dades finals.....	26
3.4 Etapa 1: Proves inicials.....	28
3.4.1 Objectiu de l'etapa .....	28
3.4.2 Preparació de les dades .....	28
3.4.3 Criteris d'avaluació de la xarxa .....	29
3.4.4 Creació de la xarxa.....	29

3.4.5	Etapa 1, Prova 0000. Paràmetres per defecte del Matlab .....	31
3.4.6	Etapa 1, Prova 1000. Augment del número de neurones .....	33
3.4.7	Etapa 1, Prova 2000. Eliminació del temps.....	37
3.5	Etapa 2: Predicció de la producció del dia següent.....	38
3.5.1	Objectiu de l'etapa .....	38
3.5.2	Preparació de les dades .....	38
3.5.3	Criteris d'avaluació de la xarxa.....	41
3.5.4	Etapa 2, Prova 0000. Determinació del número de neurones en una sola capa.....	42
3.5.5	Etapa 2, Prova 1000. Introducció d'una Hidden Layer .....	44
3.5.6	Etapa 2, Prova 2000. Reducció de la resolució de la predicció .....	45
3.5.7	Etapa 2, Prova 4000. Comparació entre logsig i tansig .....	47
3.5.8	Etapa 2, Prova 5000. Eliminació del temps.....	47
3.6	Etapa 3: Predicció del consum del dia següent.....	48
3.6.1	Objectiu de l'etapa .....	48
3.6.2	Preparació de les dades .....	49
3.6.3	Criteris d'avaluació de la xarxa.....	50
3.6.4	Etapa 3, prova 1000. Determinació del número de neurones en una sola capa .....	50
3.6.5	Etapa 3, prova 2000. Comparació entre funcions d'activació .....	53
3.6.6	Etapa 3, prova 4000. Eliminació del temps .....	53
3.6.7	Etapa 3, prova 5000. Introducció del dia de la setmana .....	54
3.7	Etapa 4: Obtenció del model de predicció del consum i de la irradiació final.....	58
3.7.1	Objectiu de l'etapa .....	58
3.7.2	Preparació de les dades .....	59
3.7.3	Criteris d'avaluació de la xarxa.....	60
3.7.4	Obtenció de la xarxa de predicció d'Irradiació.....	60
3.7.5	Comparació entre xarxes neuronals i el model teòric de predicció d'Irradiació .....	62
3.7.6	Obtenció de la xarxa de predicció del consum .....	65
3.7.7	Obtenció de la xarxa del dèficit.....	68
3.7.8	Model final.....	76

4. Impacte ambiental .....	77
4.1 Beneficis ambientals .....	78
5. Estudi econòmic .....	79
Conclusions .....	81
Bibliografia .....	84
Annex.....	87
Fitxers complementaris .....	87
Altres.....	89

# 1. Introducció

En un sistema elèctric, poder-se anticipar als canvis en la producció i el consum d'energia és de vital importància per tal de gestionar-lo. Des dels operadors dels sistemes fins als productors i distribuïdors d'energia, tenir informació avançada respecte la demanda i l'oferta amb alta precisió és clau pel seu negoci. En una micro-xarxa, on el sistema pot ser completament independent a la xarxa principal, aquesta gestió és encara més important.

L'objectiu final d'aquest treball és idear un model que permeti realitzar aquesta predicció a curt termini en una instal·lació alimentada per una micro-xarxa que alhora generi i consumeixi energia elèctrica. En una instal·lació d'aquestes característiques, conèixer el dèficit o l'excés d'energia permetrà una gestió més eficient. S'ha marcat com a objectiu tenir un model que, en introduir les dades corresponents, retorni una predicció de la generació d'energia, el consum i el dèficit o excés de les pròximes 24 hores. No entra dintre l'abast del projecte la integració d'aquest model en el sistema de control. Els sistemes predictius són només una part del complex mecanisme de control de les micro-xarxes, i el desenvolupament d'un sistema de control integrat requeriria un projecte separat a aquest.

Per tal de realitzar aquest objectiu, s'utilitzaran mètodes de *Deep Learning*, en concret l'ús de xarxes neuronals. En les últimes dècades, hi ha hagut un augment en l'aplicació de diversos models basats en xarxes neuronals en el disseny i predicció de sistemes energètics, sent cada cop més i més precisos. Degut a la naturalesa del desenvolupament de xarxes neuronals, els models obtinguts depenen exclusivament de les dades històriques del sistema amb les quals s'entrenen les xarxes. Per tant, el model final obtingut en aquest treball no podrà ser extrapolat a altres instal·lacions.

Respecte a la generació d'energia, s'ha buscat fonts de dades d'instal·lacions que utilitzessin plaques fotovoltaïques. S'ha decidit centrar-se en energia solar per diversos motius. Primer de tot, les energies renovables i la millora de la seva eficiència són clau per tal d'arribar a una situació sostenible amb els recursos naturals dels que la humanitat disposa. Segon, la producció d'energia solar segueix patrons relativament senzills de predir, en que només les hores de Sol i la climatologia afecten a la irradiació rebuda per les plaques. Això fa que la predicció d'energia solar sigui ideal per a introduir-se en el món de les xarxes neuronals. Tercer, l'existència de models empírics de la irradiació solar permet fer una comparació entre els models clàssics i els models que empren xarxes neuronals, per comprovar quin resulta superior.



## 2. Antecedents del treball

Aquest treball fa referència a dos camps de coneixement, la gestió d'una xarxa elèctrica amb generació solar, i l'obtenció d'un model predictiu mitjançant xarxes neuronals. Aquest capítol introductori pretén consolidar els diferents conceptes pertanyents a aquests dos camps que han hagut de ser estudiats en la realització del treball.

### 2.1 Gestió de xarxes elèctriques

En la Figura 2.1 es troba representat el que es coneix com una micro-xarxa. Les micro-xarxes permeten integrar dintre un sistema fonts d'energia renovables (aquest treball es centrarà en el cas particular de plaques fotovoltaïques), generadors convencionals (com per exemple motors de dièsel), sistemes d'emmagatzemat d'energia (com ara bateries), i les diferents càrregues de la instal·lació on es troba la micro-xarxa. Aquesta micro-xarxa pot estar connectada a la xarxa principal o estar aïllada.



Figura 2.1 Esquema d'una micro-xarxa. Font: [1]

Connectant a totes aquestes parts es troben els sistemes de gestió d'energia. Aquests sistemes són els que s'encarreguen de gestionar els diferents components del sistema, i optimitzar-ne el rendiment. Aquests sistemes normalment estan formats per un sistema jeràrquic de control (Figura 2.2) [1], que inclou els següents nivells:

- **Nivell primari:** És l'encarregat de controlar el voltatge i la corrent a nivell local, a cada un dels elements de la xarxa.
- **Nivell secundari:** S'ocupa del control de qualitat de la potència, com ara la restauració de tensió o freqüència, així com del desequilibri de tensió i la compensació harmònica. També s'encarrega de la sincronització i l'intercanvi d'energia entre la micro-xarxa i la xarxa principal, o altres micro-xarxes.

- **Nivell terciari:** L'objectiu del control terciari és optimitzar l'operació de tota la xarxa per assolir millor l'eficiència i millor rendiment econòmic. Es podria considerar com el nivell que aporta intel·ligència a la gestió de la xarxa.

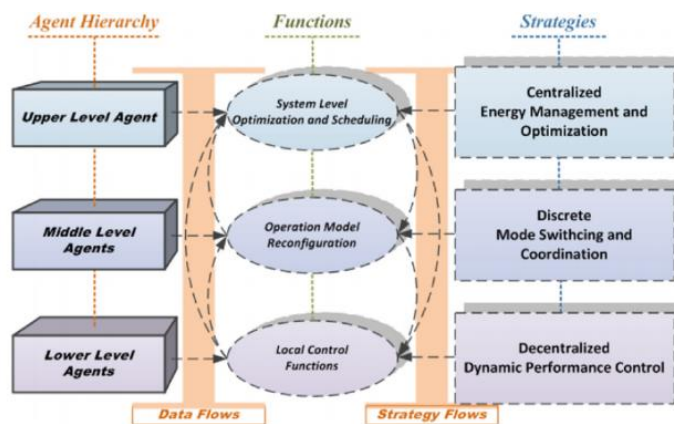


Figura 2.2 Diagrama de l'estructura jeràrquica del sistema gestor d'una micro-xarxa. Els nivells primari, secundari i terciari estan organitzats de baix a dalt. Font: [1]

Dintre del nivell terciari, cal que aquest tingui la informació necessària per tal de prendre les decisions de gestió del sistema adequades. És en aquest punt on entrarà el model predictiu que s'obindrà en aquest treball. Si el sistema de control terciari coneix una aproximació segura de la demanda de les càrregues i la producció d'electricitat per part de les plaques fotovoltaïques en les pròximes hores, podrà executar les seves funcions d'optimització més acuradament.

Com a exemple de la necessitat d'incloure models predictius en el control terciari de xarxes elèctriques, es posa el cas d'un sistema que preveu un pic en la demanda que la generació solar no podrà proveir completament. El sistema avançar-se a aquest dèficit i encendre el generador dièsel preventivament. Aquest exemple és bàsic, però en un sistema tant complex com pot arribar a ser una xarxa elèctrica, tenir una visió del futur permet aconseguir un funcionament més òptim i econòmic.

## 2.2 Energia solar

La gestió d'una micro-xarxa amb fons renovables té la dificultat afegida de que la quantitat d'energia generada depèn completament de factors externs (del Sol en el cas de les plaques fotovoltaïques, del vent en el cas de generació eòlica), a diferència de les fonts convencionals en que es té control complet de la generació. Poder afegir models predictius a aquesta generació no controlada permet un major rendiment de la instal·lació.

En la introducció ja s'han exposat els motius pels quals es va decidir optar pel cas de generació d'energia mitjançant plaques fotovoltaïques. Aquests són:

- Interès en les fonts d'energia renovable de cara el desenvolupament sostenible de la humanitat.
- Relativa senzillesa i periodicitat en els perfils d'irradiació, sobretot en els dies clars, com s'il·lustra a la Figura 2.3.
- Existència de models empírics amb els que comparar els resultats obtinguts amb les xarxes.




Figura 2.3 Exemple del perfil d'irradiació solar típic d'un dia clar. Font: [2]

La generació d'energia solar està basada en l'efecte fotoelèctric. Quan una superfície s'exposa a la radiació electromagnètica per sobre d'una certa freqüència (depenent del material), els fotons impacten i penetren la superfície. Dintre la superfície, els electrons dels àtoms que la formen interactuen amb els fotons i són alliberats. Es produeix una circulació d'electrons pel material que pot ser aprofitada per a obtenir corrent elèctric. Les plaques fotovoltaïques es fabriquen ajuntant diverses cèl·lules fotovoltaïques fabricades generalment amb silici (a la Figura 2.4 s'observa un esquema d'aquestes cèl·lules), ja que és el material amb el que es pot aprofitar millor l'efecte fotoelèctric amb llum solar.




Figura 2.4 Esquema d'una cèl·lula fotovoltaica. Font: [3]

El corrent que es genera en les cèl·lules fotovoltaïques és continu. És necessari la introducció d'un inversor en el sistema per a passar a corrent altern i poder connectar les plaques a la xarxa. Existeixen pèrdues en aquest inversor, reduint el rendiment de les plaques.

En el pas d'energia lumínica a electricitat es perd la gran majoria de l'energia. La majoria de panells comercials tenen un rendiment del voltant del 20% [4], però nous avenços tecnològics estan augmentant aquesta figura constantment.

A l'hora d'instal·lar una placa solar, hi ha diversos factors a tenir en compte. En funció de la localització geogràfica, cal calcular quina és la inclinació i la direcció a la que cal dirigir la placa òptimes per maximitzar la irradiació que rebrà durant el dia [2]. Hi ha casos en que les plaques contenen un motor que permet variar la inclinació en funció de l'hora del dia per així estar més temps en la zona de màxima irradiació.

## **2.3 Xarxes neuronals**

Aquest treball farà un ús intensiu de les xarxes neuronals. Les xarxes neuronals són una eina molt versàtil utilitzada en una gran multitud de camps. En concret, aquest treball es centra en l'ús de xarxes neuronals en la predicció de mostres futures de series temporals. Per tal de poder realitzar aquestes prediccions, cal tenir clars una sèrie de conceptes relacionats amb les xarxes neuronals i les series temporals. Aquest apartat té com a objectiu establir la base teòrica sobre la que es construirà la xarxa per complir l'objectiu final del treball.

### **2.3.1 Context històric**

Els orígens de les xarxes neuronals es troben a partir dels anys 40 del segle XX. El nom de xarxa neuronal prové precisament dels models inicials que es van idear, basats en circuits amb neurones connectades entre elles per simular comportament intel·ligent.

Una de les primeres neurones va ser modelitzada el 1943 pel neuro-científic Warren S. McCulloch i el lògic Walter Pitts. La neurona McCulloch-Pitts (Figura 2.5) consisteix en una suma ponderada de certs inputs, i retorna 0 si aquest està per sota d'un llindar i 1 en cas contrari. L'objectiu d'aquest model era explicar els processos de decisió complexos que succeeixen dintre el cervell.




Figura 2.5 Representació d'una neurona McCulloch-Pitts. Font: [5]

No va ser fins el 1958 que aquesta neurona va ser implementada en un perceptró. Un perceptró permet ajustar els pesos de la neurona que conté a mesura que se li apliquen inputs, de manera que la sortida obtinguda s'acosta més i més a la desitjada. El perceptró “aprèn” a mesura que s'entrena [6].

Amb aquest perceptró com a base, es van idear les primeres xarxes neuronals, interconnectant una sèrie d'aquests perceptrons, formant diverses capes o nivells, per millorar els resultats obtinguts. Aquest i altres avanços en el camps van provocar molta expectació. Un article del New York Times de 1958 assegurava que aquesta tecnologia arribaria a “caminar, parlar, veure, escriure, reproduir-se i ser conscient de la seva pròpia existència” [7].

Aquest perceptró, però, tenia un problema. Com que només es podia comprovar que la sortida final fos o no la correcta, no hi havia forma de saber com ajustar els perceptrons de les capes intermitges. Aquesta limitació, juntament amb el fet que les capacitats computacionals dels ordinadors de la època no eren suficientment potents, va culminar amb la publicació per part del fundador del Laboratori de IA del MIT Marvin Minsky del llibre seminal *Perceptrons* [8]. L'escepticisme mostrat en aquest llibre va provocar una congelació d'inversions en el camp que va durar una dècada sencera, provocant el que es coneix actualment com l'*AI Winter* (l'hivern de les Intel·ligències Artificials).

Tot i que les inversions en el camp s'havien reduït, no va significar una parada total en la recerca en aquest camp. Per tal de solucionar els problemes existents en els perceptrons es van idear els mètodes de retropropagació. Amb aquests mètodes, es podia observar l'impacte que tenia en l'error la modificació de qualsevol pes dintre de la xarxa. Mitjançant mètodes d'optimització, les xarxes podien trobar els pesos òptims per trobar l'error. La retropropagació va ser teoritzada a inicis dels anys 60, però no va ser fins al 1970 que es va implementar en ordinadors.

La idea d'aplicar retropropagació en les xarxes neuronals no va ser proposada fins el 1974 en la tesis doctoral de Paul Werbos [9]. Werbos creia que aquestes aplicacions podrien solucionar els problemes exposats a *Perceptrons*, però que la comunitat científica encara es mostrava molt escèptica en aquesta àrea. Va ser per això que va esperar fins 1982 per publicar les seves conclusions, i no va ser fins a finals dels anys 80 en que va ser el seu treball va ser republicat d'una manera clara i detallada, fet que va revolucionar el camp.

Amb l'hivern acabat i el gran augment de les capacitats computacionals dels ordinadors, les xarxes neuronals van tornar a viure un *boom*. A partir dels 90 el sector va seguir evolucionant, amb noves innovacions apareixent constantment.

### 2.3.2 Arquitectura d'una xarxa

Les xarxes neuronals estan formades per neurones connectades entre elles. En el context de xarxes neuronals, la neurona és un element al qual fent-li entrar diverses entrades (inputs), en produeix una sortida (output). La Figura 2.6 il·lustra l'estructura d'una neurona. Cada una de les variables d'entrada ( $X_i$ ) té assignat un pes o *weight* ( $\alpha_i$ ). La suma del producte de les entrades pels seu pes s'introdueix a una funció d'activació o *activation function*, una funció no lineal que obté el resultat que surt de la neurona  $Z_m^j$ .

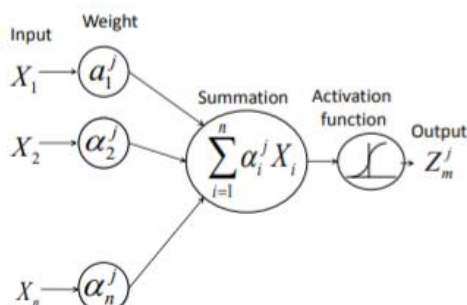


Figura 2.6 Representació de una neurona. Font: [10]

Aquestes neurones estan agrupades per capes o *layers*. La primera d'aquestes capes es coneguda com la *input layer*, seguida per un número de capes intermitges anomenades *hidden layers*, i per la capa final, *output layer*. Els resultats obtinguts per cada una de les neurones de la primera capa són utilitzats com a inputs per les neurones de la segona, els resultats de la segona són utilitzats com a inputs per les neurones de la tercera, etc. De l'*output layer* surten els resultats de la xarxa. Aquesta estructura amb nivells es el que es coneix com *Deep Learning*.

A la Figura 2.7 es veu un exemple d'una xarxa neuronal amb tres capes intermitges, cada una amb nou neurones (representades per cercles). Que les neurones tinguin més d'una

connexió sortint no indica que generin més d'una sortida, sinó que la mateixa sortida és enviada a totes les neurones de la capa següent.




Figura 2.7 Exemple d'una xarxa neuronal. Font: [10]

L'obtenció d'una xarxa neuronal que permeti complir amb la seva funció requereix d'un procés d'ajust dels diferents pesos de cada neurona fins trobar els pesos adequats. En general, al crear una xarxa s'obté un model que "interpreta" les entrades i donarà un resultat que s'acostarà al valor objectiu.

Les xarxes neuronals permeten obtenir models molt més complexos i precisos que els que es podien fer amb les regressions clàssiques. Un dels preus que s'ha de pagar per obtenir aquesta complexitat és la dificultat d'entendre exactament la interpretació de cada pes que realitza la xarxa. Un no pot agafar un dels pesos de la xarxa i raonar que significa el seu valor d'una manera directe. Les xarxes neuronals s'acostumen a tractar com caixes negres (se li introdueixen entrades i es produeix una sortida, i no interessa que passa entremig) degut a aquest fet. Si que és cert que s'han fet estudis que entren en detall en aquesta àrea [11], però queda fora de l'abast d'aquest treball.

### 2.3.3 Disseny de xarxes

El disseny de xarxes neuronals té com a objectiu trobar els valors dels pesos de cada neurona que minimitzen l'error entre el resultat obtingut per la xarxa i el resultat real. Per a fer aquest disseny, cal tenir presents els següents punts:

- El número de neurones per cada capa, i el número de capes de la xarxa. A major complexitat de la xarxa, es poden refinar més els resultats. Però no és convenient augmentar-la indiscriminadament. Les xarxes neuronals requereixen d'una capacitat de computació elevades, i cal tenir present que la xarxa ha de poder treballar dintre d'uns marges de temps limitats. Apart d'això, es pot produir *overfitting* (veure el capítol 2.3.5 Overfitting i Underfitting).
- Tenir especial cura amb les dades amb les que s'alimenta la xarxa. Introduir *outliers* pot afectar negativament amb els resultats obtinguts. També cal fer una tria sobre quins



factors seran utilitzats com a entrades i quins no. Si s'entrena la xarxa amb dades incompletes, o que presenten biaixos de selecció, els resultats que s'obtingran també seran incomplets o inclouran biaixos.

Existeixen diverses funcions d'activació, i no hi ha cap ciència certa que pugui garantir quina és la més adequada per cada aplicació. Cal realitzar les proves suficients per tal de descobrir quina funció permet la màxima precisió. Aquest treball treballarà amb les funcions Log-sigmoide i Tan-sigmoide (abreviades com logsig i tansig respectivament), ja que són les dues funcions més utilitzades [12]. A la Figura 2.8 es troba la representació d'aquestes funcions.




Figura 2.8 Funcions d'activació logsig i tansig. Font: [13]

## 2.3.4 Entrenament de les xarxes

Un cop es té l'arquitectura de la xarxa dissenyada, es procedeix en l'entrenament. A grans trets, entrenar una xarxa consisteix essencialment en anar provant diversos pesos, fent una optimització dels pesos fins trobar un bon resultat. Quan es diu "anar provant", no significa que sigui un procés aleatori. Existeixen una sèrie de tècniques que permeten realitzar aquest procés d'una forma iterativa i òptima. Per entendre com s'entrena una xarxa, cal conèixer una sèrie de conceptes que s'explicaran en aquest apartat.

### 2.3.4.1 Entrades i *targets*

A l'entrenar la xarxa, se li han de proporcionar dos conjunts de dades. El conjunt entrada o *input* està format per vectors amb cada mostra de la sèrie temporal. El conjunt *target*, per la seva banda, conté els vectors que, si la xarxa funciona perfectament, haurien de ser els valors sortida de la xarxa a l'introduir les entrades. Ha d'existir una correspondència entre les dues, és a dir que cada vector *target* està aparellat amb un vector entrada.

Els paràmetres que formen el vector d'entrada són el que s'anomenen indicadors. A les entrades se li posen tantes variables com la xarxa necessiti per tenir la màxima precisió. Aquestes poden ser tant contínues (com per exemple la temperatura) com discretes (com



per exemple el color d'un objecte). Si aquests indicadors són significatius, la xarxa tindrà millor precisió. Òbviament, afegir més indicadors també comporta un augment de la complexitat de la xarxa.

### 2.3.4.2 Training, Validation i Testing Datasets

Un cop s'han preparat les dades de manera que es tenen un seguit d'inputs i els seus respectius targets, es divideixen en tres conjunts o datasets:

- Training dataset: Aquest conjunt és amb el que realment s'entrena la xarxa. Són les dades de les que la xarxa aprèn, i les que els pesos de la xarxa ajustaran.
- Validation dataset: la xarxa no té en compte aquest conjunt a l'hora d'ajustar els pesos, però si que les utilitza per avaluar la precisió de la xarxa. L'algoritme d'entrenament seguirà buscant pesos fins que trobi un model que ajusti el millor possible el Validation dataset. El fet que validation i training estiguin separats permet a la xarxa evitar l'*overfitting*.
- Test dataset: Aquest conjunt serveix per avaluar la xarxa un cop ha estat entrenada. Proporciona l'estàndard amb el que es poden comparar diversos models competidors. La xarxa en cap moment entra en contacte amb ell en l'entrenament, per tant el Test dataset serveix com a simulació de la precisió de la xarxa un cop aquesta sigui posada en marxa. En general, és bona pràctica poblar aquest conjunt amb mostres que siguin representatives de totes les situacions a les que el model es podrà enfrontar.

Respecte el rati de la divisió, no hi ha una resposta concreta. En general s'utilitza una divisió de 70% de les mostres per al Training, 15 % per Validation i 15% per Testing, com a l'exemple de la Figura 2.9, però en funció del model pot ser necessari tenir més o menys dades per a l'entrenament. Hi ha un cert punt de prova i error a l'hora de triar les proporcions correctes [14].




Figura 2.9 Divisió de les dades en els conjunts Train, Validation i Test. Els dos primers s'entren a la xarxa, mentre que el tercer es manté separat fins a l'avaluació un cop la xarxa s'ha entrenat. Font: [14]

### 2.3.4.3 Algoritme d'entrenament

Els algoritmes d'entrenament permeten arribar al punt òptim del model. Partint d'uns pesos inicials, els pesos es van ajustant seguint l'algoritme fins la fi de l'entrenament. Existeixen diversos algoritmes (com es pot veure a la Figura 2.10). Cada algoritme té les seves peculiaritats i les seves avantatges i desavantatges.

Acr.	Description
GD	Gradient descent backpropagation
GDA	Gradient descent with adaptive learning rate backpropagation
GDM	Gradient descent with momentum backpropagation
GDX	Gradient descent with momentum and adaptive learning rate backpropagation
RP	Resilient Backpropagation
CGF	Conjugate gradient backpropagation with Fletcher-Reeves restarts
CGP	Conjugate gradient backpropagation with Polak/Ribière restarts
CGB	Conjugate gradient with Powell/Beale restarts
SCG	Scaled conjugate gradient backpropagation
BFGS	BFGS Quasi-Newton backpropagation
OSS	One-step secant backpropagation
LM	Levenberg-Marquardt backpropagation

Figura 2.10 Exemples d'algoritmes d'entrenament de xarxes neuronals. Font: [15]

Un dels factors principals a l'hora d'escollir l'algoritme d'entrenament és la capacitat computacional de la que es disposa. Si bé aquest factor no és gaire important si s'utilitza un número de dades petit, a l'introduir a la xarxa una quantitat elevada de mostres dependent de l'algoritme pot no haver memòria suficient per al programa en qüestió.

Precisament per aquest motiu en aquest treball la gran majoria de xarxes s'han entrenat utilitzant l'algoritme de *Scaled Conjugate Gradient Backpropagation* (abreviat com SCG), un dels algoritmes que requereix de menys potència computacional.

Els algoritmes que utilitzen retropropagació (*Backpropagation*) ajusten els pesos en la direcció de baixada més pronunciada (el contrari del gradient), de manera que a cada iteració el model convergeix més i més al mínim. En el cas d'algoritmes de gradient conjugat, com en el cas del SCG, la cerca és fa en les direccions conjugades, que permet obtenir una convergència més ràpida que en el la retropropagació clàssica.

El SCG requereix de més iteracions per convergir que la majoria de algoritmes de gradient conjugat, però el número de càlculs dintre de cada iteració és més reduït. Per tant, requereix de menys memòria [16]. Encara que cada iteració requereixi de menys temps, al ser necessàries més quantitat d'elles, el SCG acaba tardant més que altres mètodes. És el preu a pagar per requerir menys memòria.

#### 2.3.4.4 Fi de l'entrenament

Un cop posats en marxa l'algoritme d'entrenament, aquest podria està treballant de manera il·limitada. Cal fixar alguns paràmetres per tal de definir la fi de les iteracions.

En aquest treball s'ha definit que l'entrenament finalitzi quan la *Performance* del conjunt de validació augmenti durant 6 iteracions. En altres paraules, quan la xarxa empitjora el resultat del conjunt de validació 6 cops seguits, vol dir que s'ha arribat al punt òptim i que s'ha d'acabar l'entrenament.

El paràmetre *Performance* és aquell que es defineix per avaluar la precisió de l'output de la xarxa respecte el target. Per aquest treball s'utilitza com a *Performance* el *Mean Squared Error* (MSE, error quadràtic mig), que és el que utilitza el Matlab per defecte i dels més utilitzats. Per a mantenir les mateixes unitats que les dades d'on es treu l'error, també s'utilitzarà el *Root Mean Squared Error* (RMSE), que és simplement l'arrel de l'anterior.

En l'exemple de la Figura 2.11 s'il·lustra l'exemple de l'evolució de la *Performance* en el procés d'entrenament d'una xarxa que proporciona el propi Matlab en la seva documentació [17]. Es pot observar com a partir de la iteració 9, l'error del conjunt de validació augmenta mentre que el d'entrenament segueix reduint-se. Això vol dir que s'està sobre-ajustant la xarxa i cal aturar el procés.




Figura 2.11 Exemple d'entrenament d'una xarxa neuronal. Font: [17]

Puntualment també s'ha utilitzat en el treball un màxim d'iteracions o de temps en l'entrenament. Això és necessari en els casos en que la performance segueix millorant a cada iteració, però la millora és molt reduïda. Eventualment s'arribaria al punt de convergència, però es decideix posar un límit ja que el guany en precisió no justifica invertir tant de temps.

### 2.3.5 Overfitting i Underfitting

Quan es té un conjunt de dades i es vol obtenir un model que les descrigui totes, cal trobar un equilibri entre tenir un ajust massa simple (conegut com *underfitting*) i un que sigui massa complex (conegut com *overfitting*).

L'*underfitting* es fàcil de detectar ja que la Performance de tots els conjunts no serà gaire bona. El model és massa simple, de manera que no pot ajustar totes les dades correctament. Es pot entendre com intentar ajustar una paràbola amb una recta. La recta no és el suficientment complexa com per fer l'ajust el més precís possible.

L'*overfitting* per la seva banda és un dels problemes més comuns de treballar amb xarxes neuronals. És un fenomen que apareix en models que són més complexos del que haurien de ser. Una manera senzilla d'entendre que és l'*overfitting* és imaginar-se que un model utilitza un polinomi de tercer grau per modelitzar un fenomen que en la realitat segueix una tendència quadràtica. El grau de llibertat addicional causa aquest problema.

Un model sobre-ajustat aprèn el detall i el soroll de les dades d'entrenament, de manera que a l'aplicar el model a un nou conjunt de dades el seu rendiment queda perjudicat, en intentar replicar el soroll que ha après. Es pot detectar l'*overfitting* quan la precisió del conjunt de validació comença a disminuir mentre que la d'entrenament augmenta [18].

A la Figura 2.12 es poden visualitzar aquests dos fenòmens. El punt mig entre un model massa simple i un model massa complex pot ser difícil de trobar, i aquí és on entra en joc el procés iteratiu d'obtenció de xarxes.




Figura 2.12 Visualització de les diferències entre Underfitting, Overfitting i un bon ajust. Font [18]

## 3. Creació de la xarxa

### 3.1 Desenvolupament xarxes neuronals amb Matlab

Si bé la implementació de xarxes neuronals es pot fer de moltes maneres, com per exemple programant-les a partir de llibreries en Python o C, en aquest treball s'ha decidit que es treballaria amb el programa Matlab.

Es va triar el Matlab per diferents motius, però el principal avantatge que té és que es molt més amigable per principiants que les altres alternatives. Gracies a l'extensió *Deep Learning Toolbox* [19], el procés de creació i entrenament de les xarxes és molt intuïtiu. A més, hi ha documentació extensa i tutorials online que han resolt molts dels entrebancs que s'han trobat en la realització del treball.

#### 3.1.1 Obtenció del codi base

La *Toolbox* permet obrir una interfície per crear una xarxa bàsica de forma guiada. Es dona l'oportunitat d'utilitzar datasets d'exemple ja preparats per a que l'usuari es familiaritzi, o directament seleccionar les matriu input i output que han estat creades prèviament (Figura 3.1).

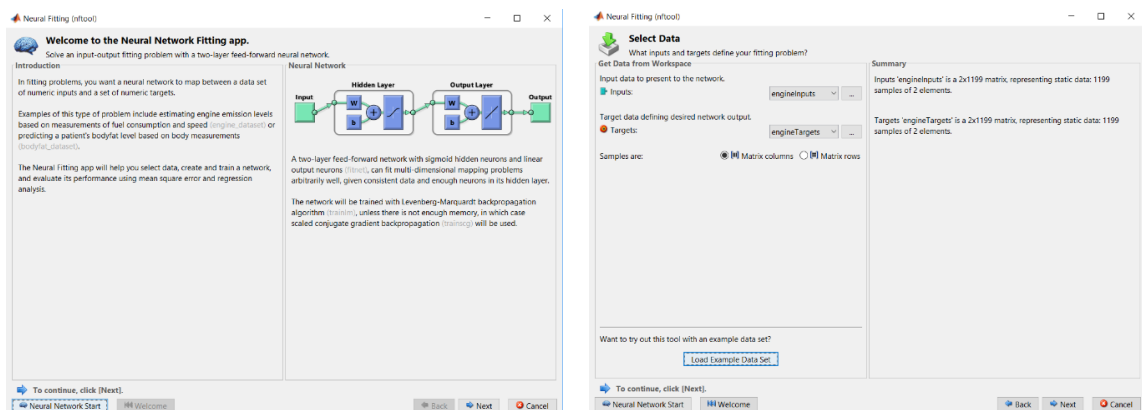


Figura 3.1 A l'esquerra, Pantalla d'inici de la interfície de creació de xarxes neuronals de la Deep Learning Toolbox. A la dreta, pantalla de selecció de inputs i outputs de la xarxa

Els següents passos consisteixen en seleccionar les divisions entre els conjunts de Training, Validation i Testing, i seleccionar el número de neurones que tindrà la xarxa. Aquesta interfície només permet tenir una sola capa a la xarxa (Figura 3.3).

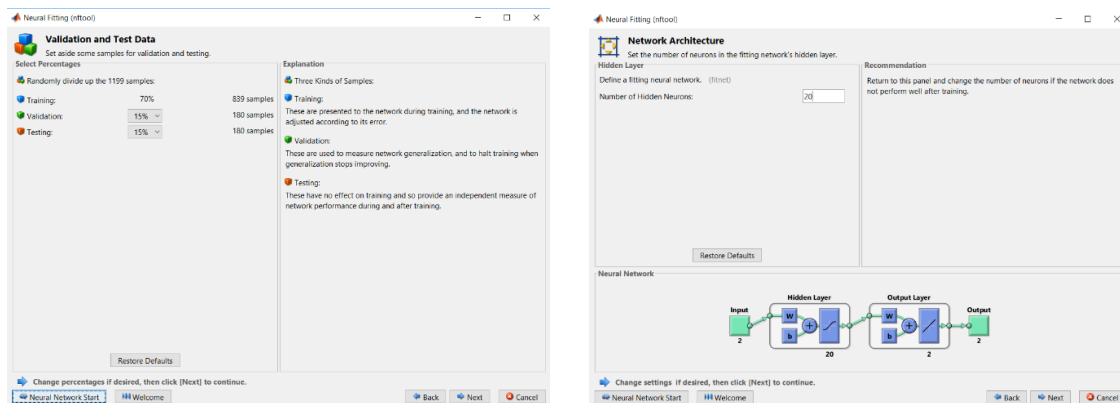


Figura 3.3 Esquerra: Divisió de les dades en els tres conjunts. Dreta: selecció de l'arquitectura de la xarxa.

Després de seleccionar l'algoritme d'entrenament, es pot entrenar la xarxa. Apareix una nova finestra des de la qual es pot veure l'evolució de l'entrenament (Figura 3.2). Des d'aquesta finestra es poden obrir diversos gràfics (com per exemple el de Performance), que es van actualitzant a mesura que la xarxa realitza cada iteració. Un cop entrenada la xarxa, es poden veure els resultats dels errors en els tres conjunts. Si un no està satisfet amb els resultats, es pot reentrenar la xarxa per intentar millorar-los.

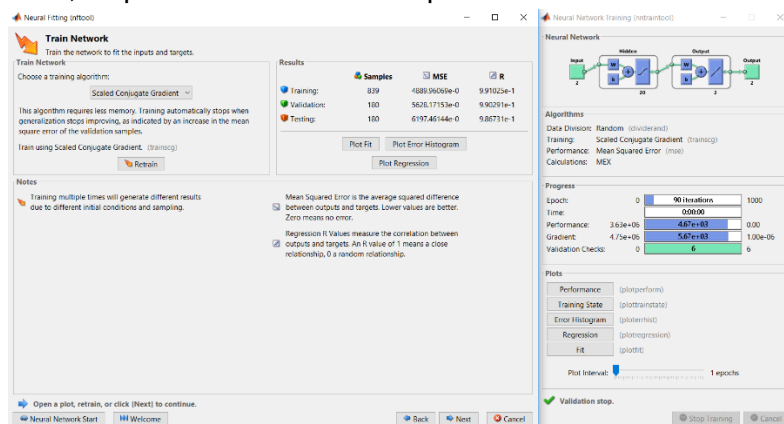


Figura 3.2 Pantalla d'entrenament i resultats

El gran avantatge que té aquesta interfície és la capacitat que té de poder generar un codi de Matlab que realitzarà tot el procediment que s'acaba de descriure de manera automàtica. Amb aquest codi com a base, es poden introduir modificacions i fer la xarxa més complexa (per exemple afegir més d'una capa o modificar la funció d'activació).

### 3.1.2 Estructura del codi de creació de xarxes neuronals

Per a l'entrenament de les xarxes es va modificar el codi resultant del procés anterior fins crear el fitxer `entrenament_xarxes_codi_base.m`, que es pot trobar a l'annex. Aquest fitxer patró és el que, amb petites modificacions, s'ha utilitzat per l'entrenament de totes les xarxes del treball. No s'entrarà en detall en explicar cada una de les línies de codi (dintre

el fitxer hi ha una explicació més específica de cada part d'ell), però si que es farà una explicació general de l'estructura d'aquest codi. L'esquema d'aquesta estructura es troba a la Figura 3.4.

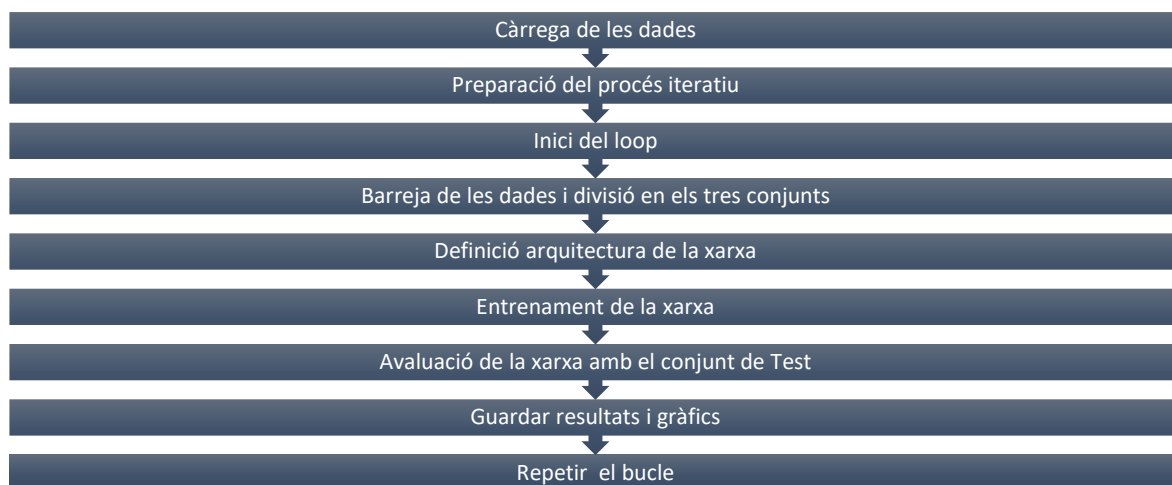


Figura 3.4 Estructura del codi d'obtenció de les xarxes

**Càrrega de les dades:** Prèviament a la posada en marxa d'aquest codi, ha hagut d'haver un procés de tractament de dades que hagi creat les matrius de Input i Target corresponents, que seran carregades al programa.

**Preparació del procés iteratiu:** Es determinen les condicions inicials de la xarxa abans de començar a iterar, i es fan altres preparatius que no cal posar dintre el bucle.

**Inici del bucle:** la introducció d'un bucle en l'entrenament de xarxes permet deixar el programa en marxa durant varies hores i aquest es dedicarà a anar creant xarxes fins a arribar a la condició de fi. De no existir un bucle, s'hauria d'engegar el programa per cada xarxa que es volgués crear una nova xarxa.

**Barreja de les dades i divisió en els tres conjunts:** Dintre cada iteració s'agafa una permutació diferent de les dades, de manera que els tres conjunts de Training, Validation i Testing seran diferents en cada iteració.

**Definició arquitectura de la xarxa:** Es crea l'estructura de la xarxa, introduint els paràmetres necessaris com l'algoritme d'entrenament, el número de capes i el seu tamany, temps màxim d'entrenament, etc.

**Entrenament de la xarxa:** Es crida la funció del Matlab d'entrenament que obrirà la pantalla de l'estat de l'entrenament de la xarxa. Aquest es el procés en que el programa pot estar diverses hores actiu.

**Avaluació de la xarxa amb el conjunt de Test:** Amb la xarxa entrenada, se li introdueix els inputs del conjunt de test. La xarxa retornarà les seves prediccions, i aquestes es compararan amb els targets reals.

**Guardar resultats i gràfics:** Amb els errors obtinguts restant les prediccions i els targets reals s'obtenen els resultats finals de la xarxa. Aquests són guardats en un fitxer apart, i també es guarden diversos gràfics de resultats que permeten la comparació entre xarxes (com per exemple l'histograma d'errors). S'obté la xarxa neuronal en sí en la forma de funció de Matlab. Gràcies a la codificació de les proves que s'explicarà a l'apartat següent, es fa fàcil organitzar els resultats de cada una de les iteracions.

**Repetir el bucle:** S'estableix una condició de fi de les iteracions, com ara un nombre màxim de neurones. Si no es compleix aquesta condició, s'estableixen els paràmetres de la següent iteració (per exemple, s'augmenta en 10 el nombre de neurones de la capa 1) i el bucle torna a començar.

### 3.2 Explicació procés de disseny iteratiu

A l'hora de treballar amb xarxes neuronals, cal realitzar un procés iteratiu. El disseny de la xarxa no és quelcom que pugui determinar-se a la primera, cal realitzar una varietat de proves. Entre els factors que poden variar entre cada xarxa, es troben:

- Número de capes
- Número de neurones per capa
- Funció de transferència de cada capa
- Mètode d'entrenament
- Format dels inputs
- Format dels outputs
- Criteris de validació
- Objectius de la xarxa

Per arribar a la xarxa final s'ha de passar per moltes xarxes diferents. S'han agrupat els diferents intents de creació de xarxes en diverses etapes. Les etapes estan diferenciades en funció de l'objectiu que es té en aquell grup de proves. No es farà un anàlisi exhaustiu de cada una de les proves. No tots els intents s'inclouen en el treball (de manera que es poden produir salts en la numeració de les proves), degut a que o bé han estat fallits o no es pot extreure cap conclusió útil d'ells. El recull inclou els que han estat més rellevants.



No només el disseny de les xarxes passa per un procés iteratiu. L'experiència guanyada en cada prova, juntament amb la recerca que es realitza en paral·lel, dona lloc a la introducció de millores, optimitzacions o canvis de criteris en el disseny de les xarxes, que podrien ser aplicats a les proves. Degut a que cada iteració requereix d'una preparació de les dades, entrenament de les xarxes i validació de resultats, es dona el cas de necessitar temps considerables de computació. Per prioritzar el temps invertit en noves proves, exceptuant aquelles en que aquests canvis tindrien un impacte elevat, no s'han repetit les iteracions antigues. Tots els canvis en els procediments, però, estan indicats en el moment en que s'han començat a aplicar.

### 3.2.1 Codificació de les proves

Per tal de organitzar les diverses proves, s'ha establert un sistema de codificació per cada una d'elles. Aquesta organització estableix una jerarquia entre etapes, proves i iteracions:

**Etapes:** Cada etapa difereix molt en paràmetres i objectiu respecte les altres.

**Proves:** En cada prova d'una etapa s'experimenten diferents paràmetres per tal d'assolir l'objectiu de l'etapa. Cada etapa conté un número de proves, a les que a cada una se li assigna un número de 4 dígitos 0000, 1000, 2000, etc.

**Iteracions:** En casos en que s'hagi de realitzar un procés iteratiu per identificar el valor d'un paràmetre més òptim (com és el cas del número de neurones a la xarxa), deixant la resta de paràmetres iguals, es definirà com a iteració. El número d'iteració s'afegeix al codi de la prova, de manera que s'obté el codi final 0000, 0001, 0002, 1000, 1001, etc.

## 3.3 Fonts de les dades

Al llarg de les etapes, s'utilitzen dades de fonts diverses. Les dades de les tres primeres etapes provenen de fonts públiques, i s'han usat per realitzar els diversos experiments preliminars. A partir de l'etapa 4 s'han utilitzar les dades de la instal·lació que s'ha seleccionat per la creació de la xarxa final del treball. Aquest capítol farà una breu explicació d'aquestes fonts de dades.

### 3.3.1 Etapes 1 i 2. DKA Solar Center

Per les etapes 1 i 2, es requerien dades de diversos anys de la producció d'energia solar d'una placa. Degut a que es tractava de l'inici del treball, era útil que aquestes dades

provinguessin d'una zona amb poca inestabilitat meteorològica, per tenir unes dades sense irregularitats que afectessin a la xarxa.

Es va trobar el DKASC (*Desert Knowledge Australian Solar Centre*), que va resultar ideal. Aquesta instal·lació és una demostració real de diverses tecnologies solars que abasten molts tipus, edats, marques, models i configuracions. Es tracta d'un centre que vol promoure l'ús de l'energia solar, i per tant ofereix les dades que recull de manera oberta a qui ho vulgui. A l'estar un desert, el temps és més estable que en altres llocs (precisament per això es va construir el centre allà).

El centre conté varies desenes de plaques diferents. Es va seleccionar sense cap motiu en concret la placa 1B Trina, i es van descarregar les dades d'aquesta placa [20]. La placa 1B Trina porta des de l'agost del 2013 en marxa, de manera que es disposava d'informació de diversos anys. Les dades tenien un període de mostratge de 5 minuts.

### **3.3.2 Etapa 3. Càrrega energètica a Bèlgica**

Pel que fa el consum, s'han utilitzat les dades que l'empresa Elia proporciona al públic. La xarxa Elia és la que subministra electricitat a tota Bèlgica. Es va seleccionar una xarxa tan gran ja que així no es produeixen canvis bruscos, en haver-hi sempre una demanda mínima. Les dades obtingudes arribaven des del 2014 a l'actualitat [21].

Cal mencionar que les dades de càrrega total estan basades en una combinació de càlculs, mesures i extrapolacions, degut a la dificultat que comporta tenir una mesura exacte del consum. Aquest fet no afecta gaire al treball a les proves ja que les prediccions que fa la xarxa no seran mai exactes.

### **3.3.3 Etapa 4. Dades finals**

Les dades utilitzades per la fase final del treball van ser les utilitzades en l'article *Reliability Assessment of PV Inverters with Battery Systems Considering PV SelfConsumption and Battery Sizing* [22]. L'objectiu de l'article és avaluar el funcionament dels inversors de les plaques solars en una micro-xarxa que té auto-consum i bateries. Les dades provenen de Lidenberg, Alemanya, on hi ha una instal·lació de plaques junt a un grup de 32 cases de 4 habitants, d'on s'extreu el perfil de consum.

Es va seleccionar les dades d'aquest article ja que permetien treballar amb les dades d'irradiació i de consum d'energia del mateix sistema, sent els dos conjunts de dades sincronitzats en el moment de mostratge. Com a afegit, també hi havia mostres de la

temperatura, i es va decidir comprovar si la inclusió o no d'aquestes resultava amb millora dels resultats. Amb aquest conjunt de dades es pot desenvolupar una xarxa neuronal que s'inclouria en el sistema de control de la micro-xarxa que gestioni la instal·lació.

Un aspecte negatiu que tenen aquestes dades es que corresponen només a un any. Per les xarxes neuronals, com més dades històriques són utilitzades, millor podrà ser. En aquest cas, al disposar només de 365 dies, no es podrà afegir informació relacionada amb les estacions en els models, ja que no hi ha mostres d'altres anys per a que xarxa pugui aprendre tendències entre elles.

El segon aspecte negatiu és que aquestes dades són més irregulars comparades amb les que s'han treballat anteriorment. Si s'observa la Figura 3.5, on s'han agafat les mostres de 3 dies consecutius com a representatius de com són la resta de les dades, ja es pot intuir que les xarxes tindran una dificultat addicional per poder ajustar-les, degut a l'existència de salts pronunciats entre mostres.




Figura 3.5 Segment de 3 dies de les mostres de Irradiació (esquerra) i de Consum (dreta)

L'explicació d'aquesta inestabilitat pel que fa a la irradiació és deguda a la pròpia inestabilitat climàtica de la zona on estan col·locades les plaques. A diferència de les utilitzades en l'etapa 2, que provenen d'una zona desèrtica, on en general el temps és més constant, aquestes plaques es troben a Alemanya, país amb més precipitacions i nuvolositat.

Respecte a la inestabilitat del consum, era d'esperar que fos més irregular. A l'etapa 3, al treballar amb dades provinents de tot un país, les irregularitats quedaven molt més amagades. En treballar en un sistema reduït i tancat, encendre un sol aparell tindrà un efecte molt més pronunciat en el consum global.

### 3.4 Etapa 1: Proves inicials

L'objectiu d'aquesta etapa és deixar constància de les proves que s'han realitzat en l'etapa inicial del treball. Aquestes proves han servit per familiaritzar-se amb el procediment de treball amb les dades i l'entorn de *Machine and Deep Learning de Matlab*. També s'utilitzen aquestes proves per determinar els criteris d'avaluació de les xarxes neuronals que s'utilitzaran en la resta de les fases.

#### 3.4.1 Objectiu de l'etapa

Donat que es tracta d'una primera aproximació a treballar amb xarxes neuronals, es va agafar un objectiu de trobar una xarxa que, partint de les mostres de les dues hores anteriors, doni una predicció de la producció de les següents dues hores. Es natural assumir que el que ha passat en un passat recent servirà com a indicador del que succeirà en el futur immediat. A la Figura 3.6 s'il·lustra un exemple del que es vol aconseguir.




Figura 3.6 Esquema de l'objectiu que es vol assolir en l'etapa 1

#### 3.4.2 Preparació de les dades

Per aquestes primeres proves, es va decidir per agafar els últims dos mesos de dades, corresponents a Gener i Febrer de 2019 del DKA Solar Center. Es va afegir a les dades una columna addicional que indiqués el minut del dia en que es va prendre la mostra (del 0 a les 00:00 h al 1435 a les 23:55 h). Posteriorment s'entrarà en detall sobre perquè s'ha afegit aquesta informació.

Els mesos de Gener i Febrer corresponen a l'estiu a Austràlia. A més, si s'observen les dades meteorològiques proporcionades pel DKASC, van ser dos mesos sense pluja. Es farà l'assumpció de que tots els dies estan sotmesos als mateixos factors externs (temperatura, humitat relativa, angle d'irradiació, hores de sol, etc.), tot i que en la realitat no és així. Al ser un període de temps curt, amb poca inestabilitat meteorològica, es fa la hipòtesis que l'efecte que tindrien diferències en aquests factors és negligible..

### 3.4.3 Criteris d'avaluació de la xarxa

Un cop s'ha creat la xarxa, cal avaluar el seu funcionament. L'objectiu final és que les prediccions siguin el més pròximes a la realitat possibles. Per tal de d'avaluar la precisió de la xarxa, s'utilitzaran els següents factors:

- Histograma d'errors: amb la xarxa entrenada, es fa una predicció de la producció de Gener, i es fa la resta entre els valors de predicció reals i els predits (*Targets-Outputs*). Un histograma d'aquesta resta permet veure la proximitat entre la predicció i la realitat. A la figura es veu un exemple d'histograma. Com millor és la xarxa, l'amplada de l'histograma serà més petita, i més centrada en el zero estarà. Es troba un exemple d'aquest histograma a la Figura 3.7.




Figura 3.7 Exemple d'histograma d'errors

- Performance plot: En l'apartat 2.3.4.4 ja s'ha definit el concepte de Performance. El performance plot permet veure l'evolució dels errors en els tres conjunts de dades a mesura que la xarxa s'entrena, un estudi d'aquesta evolució permet detectar irregularitats i *overfitting*.

### 3.4.4 Creació de la xarxa

Per entrenar la xarxa s'han de preparar els valors d'entrada (inputs) i els valors sortida (*targets*) que se li introduiran. Les dades des de les que es parteix contenen mostres fetes cada 5 minuts. Donat que com més dades s'introdueixin a la xarxa més complexa és aquesta, i no és del tot eficient introduir-li totes les dades possibles, el primer que es fa és agrupar les mostres de 3 en 3, calculant la mitjana, de manera que s'agafen aquestes mitges com les mostres cada 15 minuts.

La següent decisió és determinar com seran les matrius input i target. Seguint l'objectiu marcat per aquestes proves, es va determinar que la matriu input consisteix en N columnes amb les mostres de producció de  $t-7$  a  $t$  (sent cada instant  $t$  separat per 15 minuts), mentre que la matriu target consisteix en N columnes amb les mostres de producció  $t+1$  a  $t+8$ . En altres paraules, les dues matrius són iguals, però amb un desfasament de 8 mostres (2 hores). En la Figura 3.8 s'ha elaborat un esquema per a il·lustrar l'estructura d'aquestes dues matrius. Cada quadrat blau correspon a la mostra de la producció corresponent a l'hora indicada.

Per a començar a practicar amb indicadors de la producció addicionals, es va introduir l'única dada de la qual es disposa després d'haver depreciat els agents externs, el temps. És lògic pensar que, si tota la resta es manté constant, la producció d'energia solar a les 12:00 d'un dia serà similar a la que es va produir a les 12:00 els dies anteriors. Per tant, s'ha introduït a la matriu input una dada addicional (en la Figura 3.8 representada amb un quadrat groc), on s'indica el minut del dia en que comença el segment de dues hores de la columna (de 0 a 1425 min, corresponent a de 00:00 h a 23:45 h). L'objectiu és que la xarxa utilitzi l'hora de la mostra per donar els resultats.

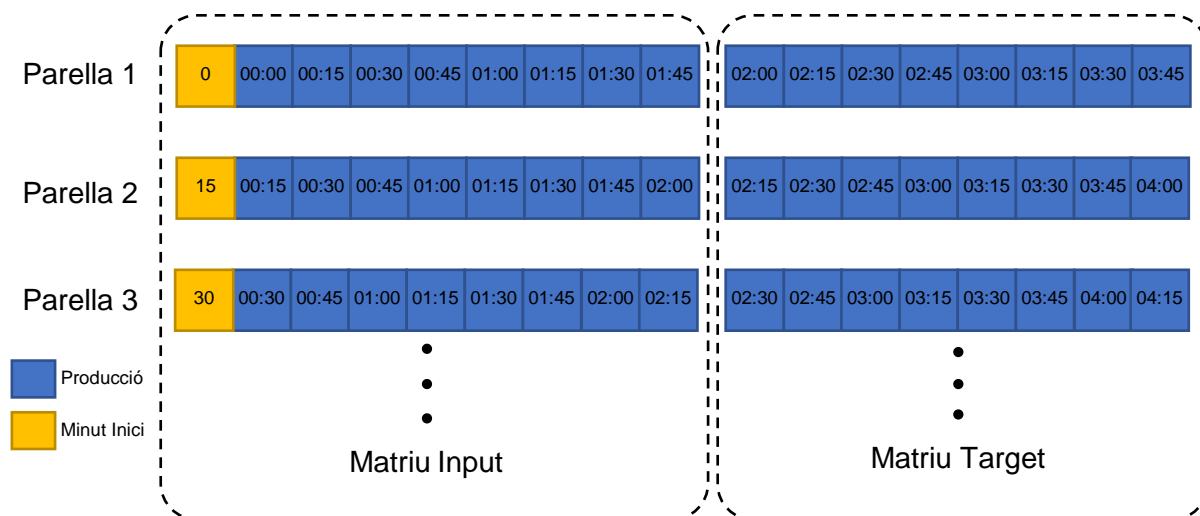


Figura 3.8 Esquema de l'estructura de les matrius Input i Target

### 3.4.5 Etapa 1, Prova 0000. Paràmetres per defecte del Matlab

Per a la primera prova, no es va modificar cap paràmetre dels que venien predefinits en la *Deep Learning Toolbox*, per tenir un punt de referència pel qual començar la resta de proves. A la Taula 3.1 es troben els valors d'aquests paràmetres:

Taula 3.1 Disseny de la xarxa de la prova 1\_0000

<b>Nom xarxa</b>	E1P0000
<b>Inputs</b>	Dades de producció d'energia Febrer 2019
<b>Format Inputs</b>	[min, prod(t-7), prod(t-6),...,prod(t)]
<b>Targets</b>	Dades de producció d'energia Febrer 2019, desplaçades 2h respecte els input
<b>Format Targets</b>	[prod(t+1),prod(t+2),...,prod(t+8)]
<b>Divisió Training/Validation/Test</b>	70/15/15 %
<b>Hidden Layer 1</b>	10 neurones
<b>Algoritme d'entrenament</b>	Levenberg-Marquardt

Fins i tot amb una xarxa simple com la que s'ha utilitzat, es poden observar bons resultats (Figura 3.9). L'histograma té una distribució d'errors elevada pròxima al zero i en el performance plot no s'aprecia que es produeixi sobre-ajust.




Figura 3.9 Prova 1\_0000: Histograma d'errors i gràfic d'evolució de la Performance

Si s'utilitzen les dades de Gener amb la xarxa creada a partir de les dades de Febrer (és a dir, utilitzant les dades de Gener com un segon conjunt de Test), es veu com els resultats en l'histograma de la Figura 3.10 segueixen sent positius, demostrant que fins i tot per una xarxa inicial amb els paràmetres per defecte del Matlab, s'ha pogut obtenir un model amb una distribució d'errors molt centrada en el zero i poc àmplia.




Figura 3.10 Prova 1\_0000: Histograma d'errors amb el conjunt de Test amb les mostres del mes de Gener

Al crear una xarxa que retorna una predicció de les següents dues hores (amb un període de 15 minuts) en la forma d'un vector de 8 mostres, fa que la representació gràfica d'aquesta predicció sigui una mica complicada. Per a poder visualitzar la precisió de la xarxa, s'ha decidit fer la mitjana de cada franja de dos hores, tant de la predicció com del target, i s'han graficat. Com que l'objectiu és veure com de pròxims són la predicció i els targets, les seves respectives mitjanes també haurien de ser pròximes.

Observant el gràfic de les mitjanes del mes de Gener a la Figura 3.11, es pot veure com, si bé és cert que la predicció aconsegueix acostar-se a la forma real, encara hi ha moltes imprecisions a arreglar. Es poden veure pics remarcables, sobretot en el cinquè dia, i també es veuen com hi ha prediccions de producció negatives. Hi ha un *outlier* molt clar el dia 25, on hi ha un valor negatiu molt elevat. La xarxa és precisa en els períodes de pujada i baixada de la producció regulars (sortida i posta de Sol), però durant el dia, la xarxa mostra els seus punts dèbils.



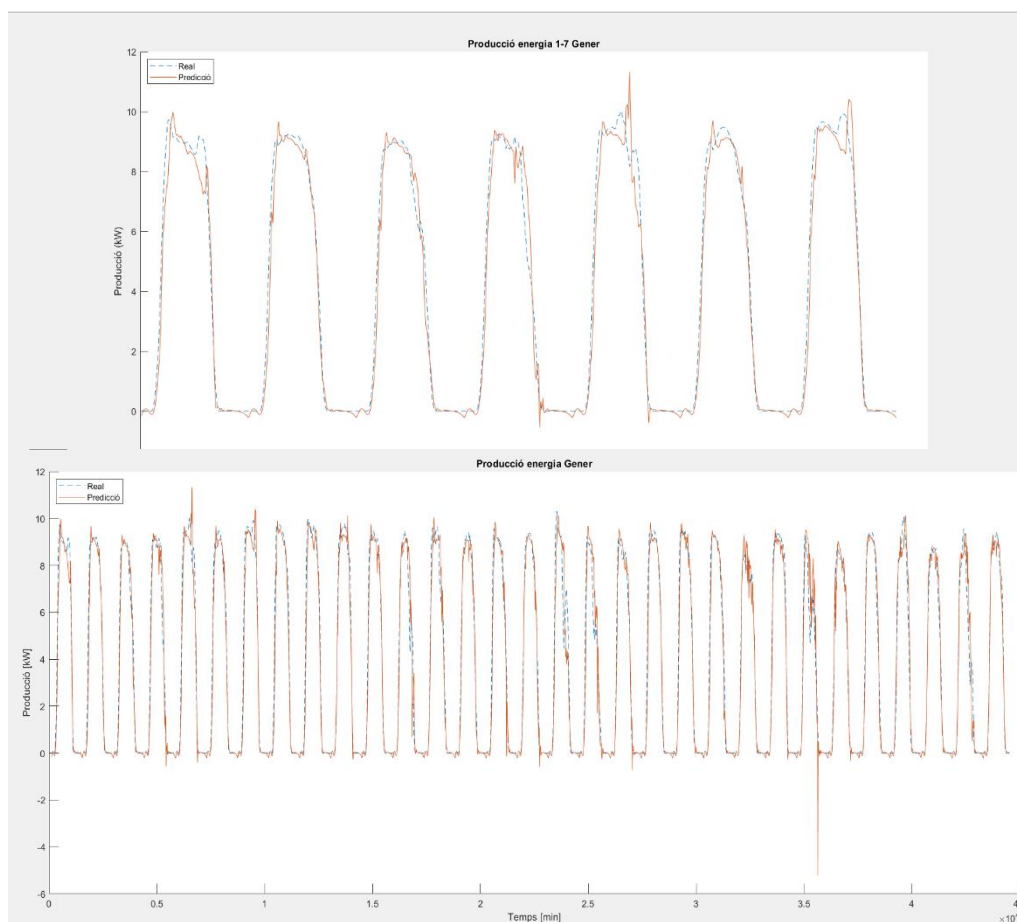


Figura 3.11 Prova 1\_0000: Mitjana de la predicció comparada amb la realitat de la primera setmana de Gener (a dalt) i del mes sencer (a sota)

### 3.4.6 Etapa 1, Prova 1000. Augment del número de neurones

El següent pas es veure com el número de neurones afecta a la sortida. Es realitza el mateix procediment que a la prova 1, però amb 250 neurones enlloc de 10

Taula 3.2 Disseny de la xarxa de la prova 1\_1000

<b>Nom xarxa</b>	E1P1000
<b>Inputs</b>	Dades de producció d'energia Febrer 2019
<b>Format Inputs</b>	[min, prod(t-7), prod(t-6),...,prod(t)]
<b>Targets</b>	Dades de producció d'energia Febrer 2019, desplaçades 2h respecte els input
<b>Format Targets</b>	[prod(t+1),prod(t+2),...,prod(t+8)]
<b>Divisió Training/Validation/Test</b>	70/15/15 %
<b>Hidden Layer 1</b>	250 neurones
<b>Algorisme d'entrenament</b>	Levenberg-Marquardt

Els resultats obtinguts en aquest cas no mostren una millora clara (Figura 3.12). La Performance empitjora respecte l'anterior, però l'histograma i la regressió tenen resultats lleugerament superiors. Si es té en compte que el temps necessari per obtenir aquesta xarxa ha estat de 10 minuts, mentre que l'anterior ha estat de 10 segons, es pot arribar a la conclusió que augmentar indiscriminadament el número de neurones no és el camí correcte per arribar a bons resultats. Es pot observar com s'està produint overfitting, ja que la performance del conjunt d'entrenament segueix millorant mentre que la de validació i test creix.

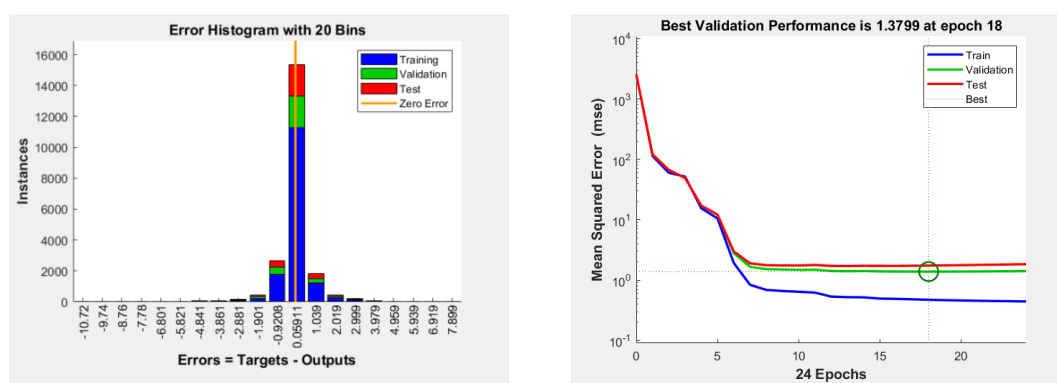


Figura 3.12 Prova 1\_1000: Histograma d'errors i performance plot

A l'utilitzar la nova xarxa amb les dades de Gener és quan es pot observar els problemes que comporta tenir una neurona molt complexa i provocar overfitting. Aquesta complexitat excessiva provoca aquests salts bruscos entre mostres (cal recordar que entre dues mostres només hi hauria d'haver un número diferent, que representa el pas de 15 minuts). Queden accentuats els problemes dels pics, tan positius com negatius (Figura 3.13).




Figura 3.13 Prova 1\_1000: Mitjana de la predicció comparada amb la realitat del mes de Gener




Figura 3.14 Prova 1\_1000: Histograma d'errors amb el conjunt de Test amb les mostres del mes de Gener

Si 250 era un número excessiu de neurones, es prova en no fer un augment tan dràstic, posant només 20 neurones a la xarxa.

Taula 3.3 Disseny de la xarxa de la prova 1\_1001

<b>Nom xarxa</b>	E1P1001
<b>Inputs</b>	Dades de producció d'energia Febrer 2019
<b>Format Inputs</b>	[min, prod(t-7), prod(t-6),...,prod(t)]
<b>Targets</b>	Dades de producció d'energia Febrer 2019, desplaçades 2h respecte els input
<b>Format Targets</b>	[prod(t+1),prod(t+2),...,prod(t+8)]
<b>Divisió Training/Validation/Test</b>	70/15/15 %
<b>Hidden Layer 1</b>	20 neurones
<b>Algoritme d'entrenament</b>	Levenberg-Marquardt

En la Figura 3.15 es troben els resultats de la prova. L'augment de neurones permet obtenir un histograma que està més centrat en el zero que l'anterior. La performance dels tres conjunts mostra resultats similars als de la prova 1.

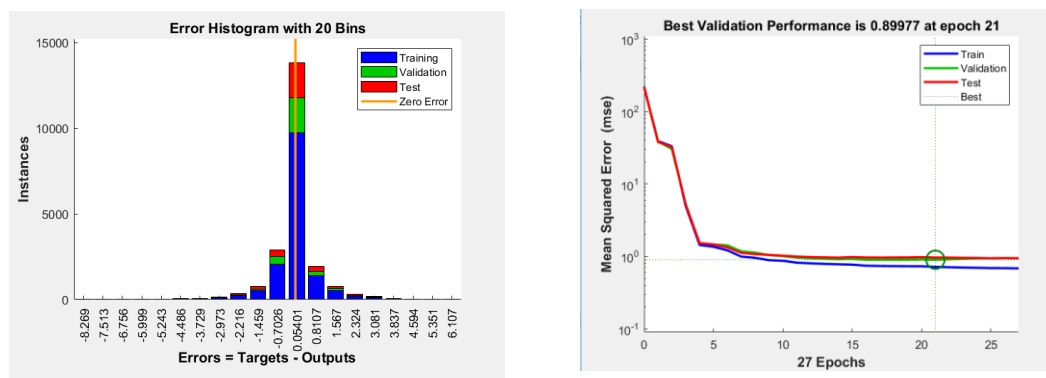


Figura 3.15 Prova 1\_1001: Histograma d'errors i performance plot de la prova

On si que es pot veure la millora és en les dades del Gener. En la representació de les mitjanes (Figura 3.16) segueixen apareixent pics irregulars, però no són tant pronunciats com ho eren en la prova 1001. L'histograma d'errors (Figura 3.17) mostra una com els errors estan més centrats i concentrats en el zero (una mitjana de 0.048 i desviació de 0.9478, respecte al cas anterior amb una mitjana de 0.0915 i 0.9823). Es pot arribar a la conclusió que un augment moderat de les neurones si que millora la fiabilitat de la xarxa.




Figura 3.16 Prova 1\_1001: Mitjana de la predicció comparada amb la realitat del mes de Gener




Figura 3.17 Prova 1\_1001: Histograma d'errors amb el conjunt de Test amb les mostres del mes de Gener

### 3.4.7 Etapa 1, Prova 2000. Eliminació del temps

Aquesta prova té com a objectiu determinar si la inclusió del minut del dia dintre de l'input serveix o no per millorar els resultats. S'ha agafat el format de la xarxa de la prova anterior, amb 20 neurones, i s'ha modificat la matriu input eliminant la dada del temps.

Taula 3.4 Disseny de la xarxa de la prova 1\_2000

<b>Nom xarxa</b>	E1P2000
<b>Inputs</b>	Dades de producció d'energia Febrer 2019
<b>Format Inputs</b>	[prod(t-7), prod(t-6),...,prod(t)]
<b>Targets</b>	Dades de producció d'energia Febrer 2019, desplaçades 2h respecte els input
<b>Format Targets</b>	[prod(t+1),prod(t+2),...,prod(t+8)]
<b>Divisió Training/Validation/Test</b>	70/15/15 %
<b>Hidden Layer 1</b>	20 neurones
<b>Algoritme d'entrenament</b>	Levenberg-Marquardt

Observant els resultats d'aquesta prova a la Figura 3.18, es pot veure ràpidament l'empitjorament del model. La performance ha augmentat, i l'histograma és més ampli i menys centrat. Amb aquests resultats es pot afirmar amb seguretat que el minut del dia realment és un indicador de la producció d'energia, cosa que era esperable.

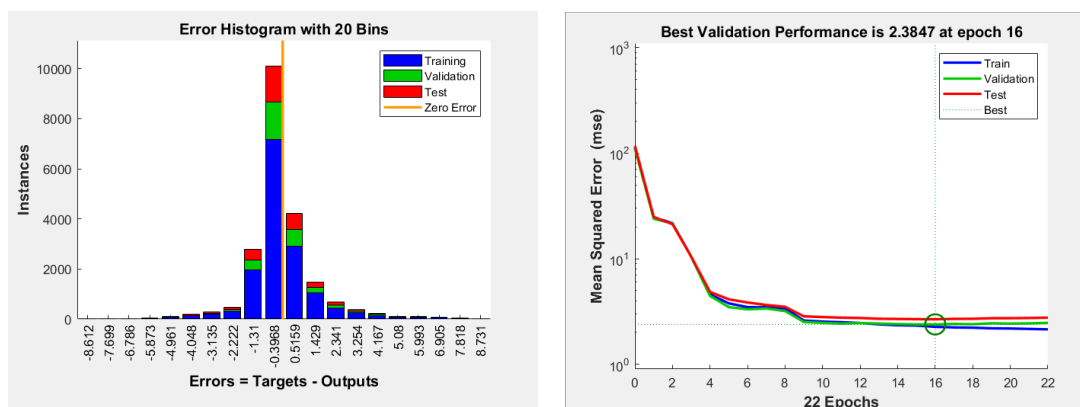


Figura 3.18 Prova 1\_2000: Histograma d'errors i performance plot de la prova

Amb les dades del Gener es reforça encara més aquesta conclusió (Figura 3.19). El gràfic de les mitjanes és mostra erràtic i imprecís. Es produeixen molts més pics que en els caos anteriors. En els períodes nocturns, on les altres xarxes predeien correctament produccions nul·les, aquesta xarxa prediu una producció d'aproximadament 0.5 kW. Tot i que l'histograma no està molt desplaçat respecte el zero (la mitjana és -0.0064), si que és molt més ampli, amb una desviació de 1.5447.




Figura 3.19 Prova 1\_2000: Mitjana de la predicció comparada amb la realitat del mes de Gener (esquerra); Histograma d'errors amb el conjunt de Test amb les mostres del mes de Gener (dreta).

### 3.5 Etapa 2: Predicció de la producció del dia següent

Amb les proves inicials queda establert que l'ús de xarxes neuronals permet la predicció a curt termini (la hora següent) a un nivell de precisió satisfactori. Si bé és cert que el model creat no és perfecte, serveix com a base per el següent pas.

#### 3.5.1 Objectiu de l'etapa

L'objectiu d'aquesta xarxa és expandir l'objectiu de les xarxes de les primeres proves. Ara el que es voldrà és donar les dades de la producció de les últimes 48h, i obtenir una predicció del que es produirà el dia següent (les següents 24h).




Figura 3.20 Esquema de l'objectiu que es vol assolir en l'etapa 2

#### 3.5.2 Preparació de les dades

En aquesta etapa s'han utilitzat totes les mostres disponibles provinents de la placa 1B Trina del DKA Solar Center, des de l'Agost 2013 fins al Febrer 2019.

Es van afegir tres columnes més a cada mostra del fitxer. Una indica el temps global, començant des de l'instant zero de la primera mostra. La segona indica el temps total des del 1 de gener de l'any de la mostra (serveix per indicar el dia), i l'última indica el temps respecte les 00:00 del dia (ja va quedar establert que l'hora del dia era un indicador útil per les xarxes). Tenint en compte que les mostres són cada 5 minuts, el que s'acaba obtenint és un fitxer de mida considerable.

Les dades des de les que es parteix contenen mostres fetes cada 5 minuts. Donat que com més dades s'introdueixin a la xarxa més complexa és aquesta, i no és del tot eficient introduir-li totes les dades possibles, es va decidir tornar agrupar cada 15 minuts, de 3 en 3. En aquest cas, però, no es va utilitzar un mètode tant directe com el de calcular la mitjana de tres mostres. La funció *decimate* [23] realitza un procés de delmació, que permet passar de  $N$  mostres a  $N/r$  mostres ( $r$  és un factor de reducció), fent passar les mostres per un filtre FIR d'un ordre determinat. Per a aquestes proves s'utilitzarà un FIR de grau 5.

Un detall que inicialment no es va preveure és que les dades obtingudes no són del tot completes. Per motius diversos (manteniment de les plaques, problemes informàtics, etc.), hi ha salts en el temps en les mostres. Per evitar posar a la xarxa blocs de dades que no són continus, s'ha editat correctament el codi de manera que si les 72 mostres no són contínues en el temps, no s'introdueixen a la matriu resultat. Aquesta consideració també es va fer a l'hora de realitzar la delmació, evitant que el filtre agrupi tres mostres les quals estan separades per diverses hores en el temps en la realitat.

Es van realitzar proves preliminars en aquesta etapa i es va demostrar que part de les mostres obtingudes no s'havien d'incloure per el bon desenvolupament de l'etapa. Es va detectar un biaix en els resultats, on s'obtenien unes prediccions amb tendència a ser superiors a la realitat. Això es pot observar en els dos histogrames d'errors de dues de les proves preliminars realitzades (Figura 3.21).

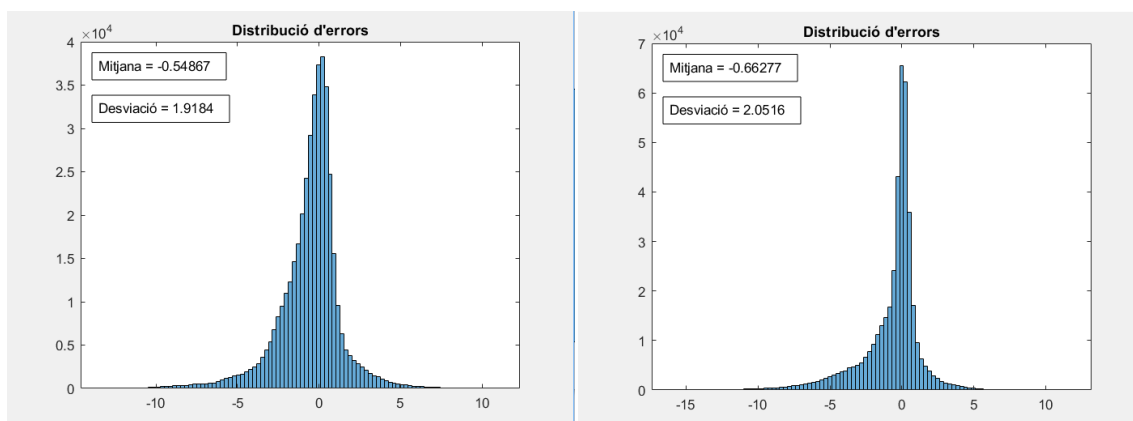


Figura 3.21 Proves preliminars de l'etapa 2. S'observa un biaix en l'histograma, sent més comuns els errors negatius (la predicció és superior a la realitat)

A l'estudiar possibles causes d'aquesta tendència, es va veure l'evolució de la producció del agost del 2013 a l'inici del 2019, amb les dades extretes directament de la font, sense cap transformació. A la Figura 3.22 es veu el resultat.

Visualment, es pot observar com els pics corresponents als anys 2013, 2014, 2015 i 2016 són molt similars, mentre que els del 2017 i 2018 són inferiors. Hi ha diverses possibles explicacions per aquest fenomen (deteriorament de l'equip, canvis realitzats a les instal·lacions, etc.), però queda fora de l'abast del treball determinar la correcta. El que sí que és clar és que no es poden utilitzar les dades de 2017 i 2018 per la validació, com s'havia fet a les proves 1 i 2. A l'estar la xarxa entrenada amb els primers 4 anys, amb producció superior, la xarxa predirà valors també superiors als del 2017 i 2018.

Per tal d'evitar que aquest error influeixi en la validació de la xarxa, es va decidir utilitzar només les dades dels 4 primers anys, que són molt més homogènies, deixant una matriu amb 130000 mostres.




Figura 3.22 Producció d'energia mes a mes

Per les matriu de input i target, es va seguir el mateix format que a les primeres proves. La matriu input consisteix en mostres de producció de  $t-48 \cdot 15-15$  a  $t$  (sent cada instant  $t$  separat per 15 minuts), mentre que la matriu target consisteix en  $N$  columnes amb les mostres de producció  $t+15$  a  $t+24 \cdot 15$ . Essencialment el que s'ha fet es separar els blocs de 72 hores que s'han obtingut en dos, els primers dos terços a input i el terç restant a target. S'han afegit dues columnes addicionals a l'input. Les dues columnes inicials de input contenen el minut des del 1 de gener de l'any i el minut des de la mitjanit de la primera mostra del bloc.

En la Figura 3.23 s'ha realitzat l'esquema d'aquestes dues matrius per a que s'entenguin millor. Si es compara la parella 1 (amb el bloc que comença l'1 de Gener a les 00:00), amb la 97 (amb el bloc que comença el 2 de Gener a les 00:00), es pot veure com la columna corresponent al minut del dia és igual (ja que són a la mateixa hora), però l'indicador del minut de l'any és diferent (en la parella 97 han passat 24h des de l'inici de l'any,



corresponent a 1440 minuts). L'objectiu d'aquestes columnes és que la xarxa introdueixi en les prediccions l'època de l'any i l'hora del dia.

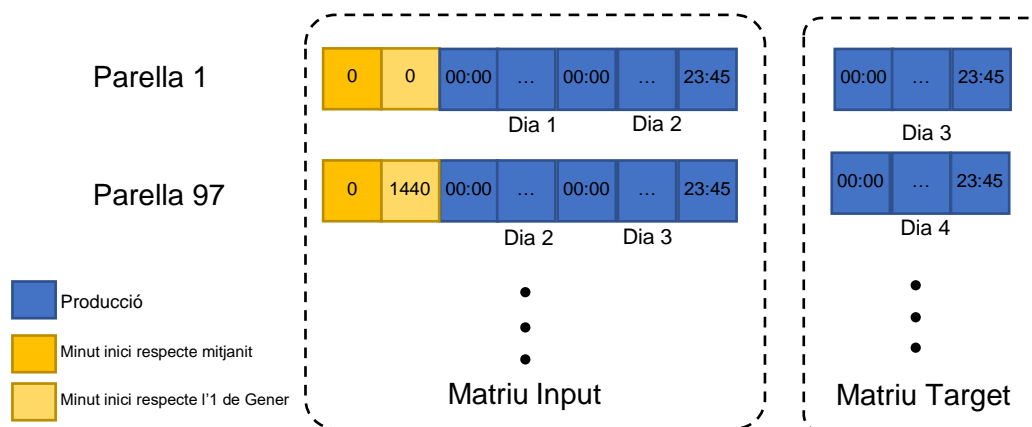


Figura 3.23 Esquema de l'estructura de les matrius Input i Target.

Es va barrejar l'ordre de les mostres i es van separar 100000 per l'entrenament i les 30000 restants per la validació. Aquesta barreja es fa per així poder validar amb mostres de tot el període, no només del final.

### 3.5.3 Criteris d'avaluació de la xarxa

Per comparar les diferents xarxes i avaluar-les, es van determinar els següents factors:

- Histograma d'errors: serveix per poder observar la distribució dels errors de forma visual. Pot servir per detectar tendències.
- Gràfics de prediccions: Donat que hi ha 30000 prediccions que es realitzen en cada mostra, no hi ha manera de incloure-les totes en un sol gràfic. El compromís al que s'ha arribat és agafar 9 d'aquestes prediccions, aleatòriament, i fer el seu gràfic. L'objectiu es poder detectar visualment les tendències de les xarxes. S'inclou també l'input que se li ha introduït a la xarxa en aquests gràfics per tenir una visió completa del que ha realitzat la xarxa.
- Mitjana d'errors: és indicadora de si els errors estan centrats en zero o no. Com més pròxima al zero, millor és la xarxa.
- Desviació dels errors: és indicadora de la dispersió dels errors. Idealment és vol que el rang dels errors sigui mínim.
- Mean Absolute Error (MAE): Mitjana del valor absolut dels errors. Com més precisa és la xarxa, més pròxim al zero és.

- Percentatge d'errors dintre del rang: S'ha establert com a error acceptable aquell que estigui en el rang  $[-1,1]$ . Aquesta mesura indica la proporció d'errors que són acceptables. L'objectiu és maximitzar-la.

### 3.5.4 Etapa 2, Prova 0000. Determinació del número de neurones en una sola capa.

El primer pas a fer en aquesta prova és, partint d'un número petit de neurones, anar augmentant la complexitat de la xarxa fins a determinar quin és el número òptim per a la predicció.

S'ha passat de tenir 9 factors a l'input i 8 a l'output a tenir 194 inputs i 96 outputs. És d'esperar que si s'utilitza un número petit de neurones com es feia a l'Etapa 1, no serà suficient per obtenir bons resultats. Per això, es va introduir al Matlab un bucle que crees una xarxa, avalués el resultat, i si el resultat no empitjorava respecte la iteració anterior, tornava a començar, augmentant el número de neurones de la xarxa.

Quan s'entrena una xarxa neuronal, encara que tots els paràmetres siguin iguals, es poden obtenir xarxes diferents. Com que hi ha aquest marge de diferències, es va establir que per aturar el bucle la xarxa havia de ser pitjor que els tres millors resultats anteriors. Això a més permet estudiar el resultat quan és supera el número òptim.

*Taula 3.5 Disseny de la xarxa de la prova 2\_0000*

<b>Nom xarxa</b>	E2P0000
<b>Inputs</b>	Dades de producció d'energia de dos dies dels anys 2013-2016
<b>Format Inputs</b>	[minut de l'any, minut del dia, prod(t-(48*4-1)), prod(t-(48*4-2)),...,prod(t)]
<b>Targets</b>	Dades de producció d'energia del dia següent de l'input
<b>Format Targets</b>	[prod(t+1),prod(t+2),...,prod(t+24*4)]
<b>Divisió Training/Validation/Test</b>	70/30 %
<b>Hidden Layer 1</b>	De 20 a 350 neurones
<b>Algoritme d'entrenament</b>	Trainscg

En el gràfic (Figura 3.24) es pot observar com la precisió de la xarxa augmenta amb l'increment del número de neurones. Aquest augment, però, no és lineal, i passades les 250 neurones les millores són ínfimes. Es pot comparar també els histogrames amb 20 i 320 neurones (Figura 3.25), i s'aprecia la superior precisió del segon, sent més estret.




Figura 3.24 Prova 2\_0000: Evolució del percentatge d'errors dintre del rang i de la desviació en funció del número de neurones de la xarxa




Figura 3.25 Prova 2\_0000: Comparació dels histogrames d'errors de les xarxes de 20 (esquerra) i 320 (dreta) neurones

Mirant les nou prediccions graficades a la Figura 3.26, es pot observar com en casos on la producció no ha patit irregularitats, com la 2 o 8, la predicció és pràcticament idèntica en la realitat. La xarxa, però, té dificultats en la predicció de irregularitats que poden succeir, com és el cas de les prediccions 4 o 6.

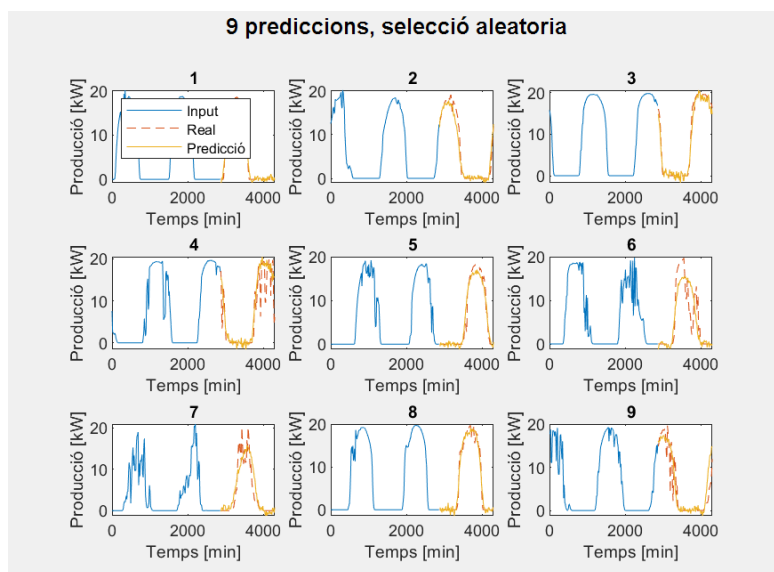


Figura 3.26 Prova 2\_0000: Prediccions aleatòries. Comparativa entre la realitat (vermell) i la predicció de la xarxa (groc)

Un detall que s'ha pogut observar en aquesta prova, i que es manté en la resta de l'etapa, és com la mitjana dels errors és molt pròxima a zero. Si que és cert que fluctua una mica, però en general, fins i tot els casos amb menys neurones, la xarxa està ben centrada.

### 3.5.5 Etapa 2, Prova 1000. Introducció d'una Hidden Layer

Si la primera prova tenia com a objectiu veure l'efecte d'un augment de la complexitat de la xarxa via l'augment de neurones, en aquesta es vol comprovar si la inclusió de una Hidden Layer addicional augmenta la precisió de la xarxa. Es realitza el mateix procés iteratiu que en la prova anterior, augmentant progressivament el nombre de neurones a ambdues capes.

Taula 3.6 Disseny de la xarxa de la prova 2\_1000

<b>Nom xarxa</b>	E2P1000
<b>Inputs</b>	Dades de producció d'energia de dos dies dels anys 2013-2016
<b>Format Inputs</b>	[minut de l'any, minut del dia, prod(t-(48*4-1)), prod(t-(48*4-2)),...,prod(t)]
<b>Targets</b>	Dades de producció d'energia del dia següent de l'input
<b>Format Targets</b>	[prod(t+1),prod(t+2),...,prod(t+24*4)]
<b>Divisió Training/Validation/Test</b>	70/30 %
<b>Hidden Layer 1</b>	De 30 a 190 neurones
<b>Hidden Layer 2</b>	De 15 a 95 neurones
<b>Algoritme d'entrenament</b>	Trainscg

La conclusió a la que s'arriba directament al veure els resultats és com, tot i ser teòricament més complexa, la qualitat de la xarxa amb dues capes és pitjor. Amb aquest experiment es pot observar els efectes de l'overfitting, i com afecta negativament a l'eficàcia de la xarxa. La Figura 3.27 mostra l'empitjorament de la precisió a l'incloure la segona capa.




Figura 3.27 Prova 2\_1000: Comparació de la precisió entre xarxes amb una i dues capes ocultes

### 3.5.6 Etapa 2, Prova 2000. Reducció de la resolució de la predicció

Amb el format de les dades en les proves anteriors, s'havien d'introduir 194 inputs i 92 outputs a la xarxa. El fet de tenir tantes variables alhora pot dificultar la tasca de minimitzar l'error per cada una d'elles. Per això, es va decidir estudiar quin efecte es té si enlloc de tenir una resolució de 15 minuts en la predicció, es relaxessin els criteris i només es busqués una predicció horària de les següents 24h.

Per a passar de mostres cada 15 minuts a mostres cada 60 s'ha tornat a aplicar la funció *decimate*, aquest cop amb factor de reducció 4 i grau del filtre 5, a la matriu target. La matriu input s'ha mantingut igual, ja que només es vol reduir la predicció.

Taula 3.7 Disseny de la xarxa de la prova 2\_2000

<b>Nom xarxa</b>	E2P2000
<b>Inputs</b>	Dades de producció d'energia de dos dies dels anys 2013-2016
<b>Format Inputs</b>	[temps any, temps dia, prod(t-(48*4-1)), prod(t-(48*4-2)),...,prod(t)] (cada 15 minuts)
<b>Targets</b>	Dades de producció d'energia del dia següent de l'input
<b>Format Targets</b>	[prod(t+1),prod(t+2),...,prod(t+24)] (cada 60 minuts)
<b>Divisió Training/Validation/Test</b>	70/30 %
<b>Hidden Layer 1</b>	De 30 a 320 neurones
<b>Algoritme d'entrenament</b>	Trainscg

En la Figura 3.28 s'aprecien els resultats d'aquesta prova. Hi ha un augment d'un 4% d'errors dintre del rang objectiu respecte a la prova 0000, i la desviació també és lleugerament inferior. Es comprova com, efectivament, al demanar-li a la xarxa que predigui una quarta part dels valors que feia inicialment, aquesta dona millors resultats, que era el resultat esperable.




Figura 3.28 Prova 2\_2000: Evolució del percentatge d'errors dintre del rang i de la desviació en funció del número de neurones de la xarxa

En el recull de prediccions (Figura 3.29), es pot apreciar aquesta millora. En les prediccions 5, 6, 7 i 8 la predicció és pràcticament idèntica a la realitat. Degut a que les dades del tercer dia estan “suavitzades”, a l’haver-se aplicat el filtre, no hi ha els pics pronunciats que es veuen en dies d’alta inestabilitat (com en la predicció 2), de manera que la xarxa pot resultar molt més precisa.

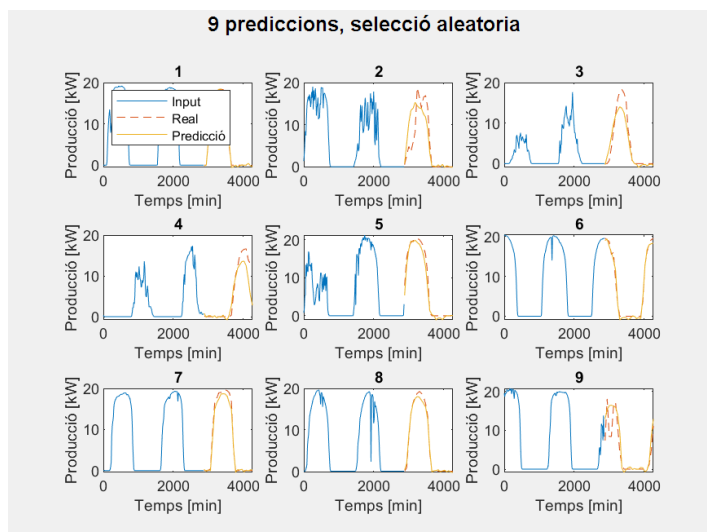


Figura 3.29 Prova 2\_1000: Prediccions aleatòries. Comparativa entre la realitat (vermell) i la predicció de la xarxa (groc)

### 3.5.7 Etapa 2, Prova 4000. Comparació entre logsig i tansig

Les funcions d'activació logsig i tansig són dues de les més utilitzades en xarxes neuronals. Aquesta prova parteix de la 0000, amb els mateixos paràmetres, però utilitzant la funció de transferència tansig per veure quina és la més adequada per modelitzar la producció d'energia solar.

*Taula 3.8 Prova 2\_4000: Comparativa entre les funcions d'activació logsig i tansig*

Xarxa	Mitjana	Desviació	% errors dintre el rang
Logsig	0,0011417	2,6596	61,4207
Tansig	0,014958	2,7051	59,2405

Comparant el resultat en la Taula 3.8 de les dues funcions d'activació, es pot veure com la funció logsig és la que dona millors resultats. Aquesta conclusió no és definitiva. Si bé és cert que en aquest cas la funció logsig es mostra superior, si es canvia el format de les dades o l'horitzó de predicció, pot ser que no ho sigui. Tampoc significa que no hi ha una funció que en aquest cas és encara millor a logsig. Però de moment, es mantindrà logsig com la funció que s'utilitza en les següents etapes.

### 3.5.8 Etapa 2, Prova 5000. Eliminació del temps

Igual que es va realitzar en l'etapa 1, en aquesta prova s'han eliminat de la matriu input aquelles columnes amb informació relacionada amb el temps. En aquesta etapa es tenien dues columnes temporals, una amb el minut respecte les 00:00 del dia de la primera mostra de l'input, i una altra amb el minut respecte les 00:00 del 1 de Gener de l'any de la primera mostra de l'input. S'han realitzat 4 proves, una amb les dues columnes, una sense la columna del temps del dia, una sense la columna del temps de l'any, i l'altre sense les dues. Observant les quatre combinacions possibles es pot determinar quin dels indicadors és rellevant o no.

La comparació entre els quatre casos es troba a la Taula 3.9. I el que és més sorprenent és la gran proximitat que tenen els quatre casos. Si bé és cert que la xarxa que no disposava de la informació del temps és la que té pitjors resultats al llarg de la taula, segueixen sent molt pròxims als altres. En el cas de que només es disposa d'un dels indicadors de temps, les xarxes fins i tot milloren, tot i que tant poc que entra dins del marge de diferència que tenen les pròpies xarxes.

Taula 3.9 Prova 2\_5000: Comparativa dels resultats de les quatre xarxes

Xarxa	Mitjana	Desviació	% errors dintre el rang	MAE
Sencera	-0,00073218	2,6586	62,3601	1,5134
Només T dia	0,01032	2,6487	61,7866	1,5197
Només T any	-0,0039043	2,6254	62,5075	1,5074
No T	0,0054496	2,658	61,5231	1,5338

Hi ha un contrast molt gran entre aquest resultats i els que es van obtenir en l'etapa 1 eliminant el temps. En les prediccions en intervals de dues hores, saber l'hora del dia era un indicador important, mentre que a l'intentar predir les pròximes 24 h amb informació de les 48 prèvies, la seva inclusió no resulta significativa.

La conclusió que es pot extreure és que l'historial de producció és molt més determinant a l'hora de predir el futur que el punt temporal on s'està. Al donar-li a la xarxa les 192 mostres prèvies, ja té informació suficient per a fer una bona predicció, sent la informació del temps no determinant.

### 3.6 Etapa 3: Predicció del consum del dia següent

En aquesta etapa es va deixar aparcat la producció d'energia per centrar-se en l'altre aspecte del treball, el consum d'electricitat.

#### 3.6.1 Objectiu de l'etapa

L'objectiu de l'etapa es analitzar si l'experiència adquirida en l'etapa 2 amb la producció d'energia es pot aplicar al consum d'energia. Essencialment es repeteixen les diferents proves que s'han realitzat a l'etapa 2, però amb les dades de la consumició d'energia, amb la intenció de veure possibles diferències i similituds. Per això, la xarxa tornarà a estar alimentada amb les mostres dels últims dos dies, per preveure el dia següent (Figura 3.30)




Figura 3.30 Esquema del sistema de l'etapa 3



### 3.6.2 Preparació de les dades

Afortunadament, el format en que les dades estaven disponibles ha facilitat molt el condicionament de les dades. Simplement s'ha hagut d'ajuntar els fitxers amb les mostres anuals de producció, i agrupar les mostres cada 3 dies. S'ha tornat a afegir una columna amb la informació del minut en que s'ha pres la primera mesura del bloc, i un altre amb el dia de l'any. Si bé és cert que en l'etapa 2 s'ha vist que el temps no era molt determinant, es vol comprovar si en la consumició aquest fenomen es repeteix. S'ha tornat a realitzar un esquema de les dues matrius en la Figura 3.31.

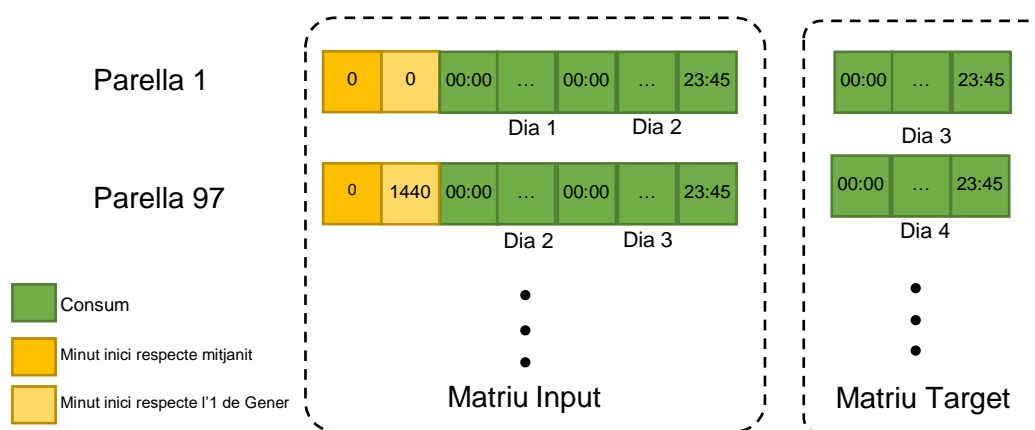


Figura 3.31 Esquema de l'estructura de les matrius Input i Target.

Ja que les dades ja estaven disponibles amb un període de mostratge de 15 minuts, no ha sigut necessari cap procés de filtratge.

Al representar totes les dades de consumició (Figura 3.32) no s'aprecia que hi hagi anomalies que siguin necessàries d'eliminar per no afectar a la xarxa, així que s'han agafat totes les mostres per a aquesta etapa. En els casos esporàdics on hi ha mostres en blanc per motius diversos, simplement s'han eliminat tots els blocs que contenen aquestes mostres buides.




Figura 3.32 Consum d'electricitat a Bèlgica des del 2014

Es va tornar a fer una barreja de l'ordre de les mostres, i es van separar 100000 mostres per l'entrenament i les 46000 restants per la validació.

### 3.6.3 Criteris d'avaluació de la xarxa

Els criteris d'avaluació romanen similars als de l'etapa 2. Es segueixen estudiant l'histograma d'errors, 9 prediccions aleatòries, la mitjana i la desviació per comparar les diferents xarxes. S'han introduït, però, dos canvis:

- Canvi dels límits del rang objectiu a  $[-100, 100]$  kW. La quantitat de kW consumits a tot Bèlgica és òbviament de diversos ordres superiors a les de la producció d'una sola placa solar. En general, les mostres oscil·len entre els 6000 i els 12000 kW. S'ha determinat que es vol maximitzar el número d'errors que tinguin un valor absolut inferior a 100.
- Ús del RMSE (*Root Mean Squared Error*). L'arrel de l'error quadràtic mitjà es calcula com l'arrel de la mitjana dels errors al quadrat. S'ha optat per utilitzar el RMSE enlloc del MAE ja que en el primer, en elevar els errors al quadrat, els errors que són més grans augmenten la mitjana. En altres paraules, el RMSE és penalitzat per aquells errors de gran magnitud.

### 3.6.4 Etapa 3, prova 1000. Determinació del número de neurones en una sola capa

La prova 1000 de l'etapa 3 és idèntica en concepte a la 0000 de l'etapa 2. S'ha tornat a realitzar un procés iteratiu, augmentant progressivament el número de neurones fins trobar el número òptim que permet obtenir la màxima precisió. La Taula 3.10 està completada amb tots els paràmetres de disseny d'aquestes xarxes.

Taula 3.10 Disseny de la xarxa de la prova 3\_1000

<b>Nom xarxa</b>	E3P1000
<b>Inputs</b>	Dades de càrrega d'energia de dos dies dels anys 2014-2019
<b>Format Inputs</b>	[temps any, temps dia, consum(t-(48*4-1)), consum(t-(48*4-2)),...consum(t)]
<b>Targets</b>	Dades de càrrega d'energia 2014-2019, del dia següent a l'input
<b>Format Targets</b>	[consum(t+1),consum(t+2),...,consum(t+24*4)]
<b>Divisió Training+Validation/Test</b>	70/30 %
<b>Hidden Layer 1</b>	De 10 a 230 neurones
<b>Algoritme d'entrenament</b>	Trainscg

A l'analitzar els resultats, el que es pot observar a primera vista és com els histogrames d'errors són més eixamplat que el que s'obtenien amb les produccions. En l'etapa anterior l'usual era veure una concentració elevada d'errors propers al zero, mentre que en aquesta la concentració en el zero no és tan exagerada. A la Figura 3.33 es mostra una comparació entre dos de les millors distribucions per cada un dels dos casos per il·lustrar aquest fet.

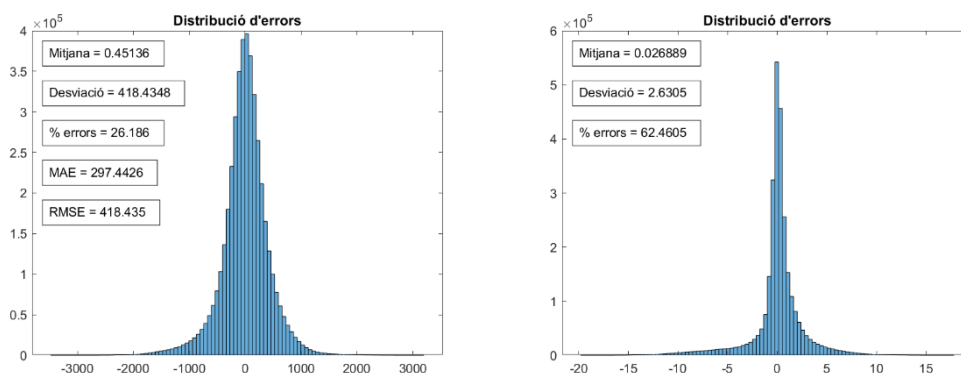


Figura 3.33 Prova 3\_1000: Comparació entre les distribucions d'errors del consum d'energia (esquerra) i producció d'energia (dreta)

Era d'esperar que les distribucions d'errors no serien tan precises en el consum d'energia. Al cap i a la fi, la quantitat de factors que intervenen en la càrrega a la xarxa elèctrica és molt superior a la de producció d'energia solar (on a grans trets intervenen principalment la posició del sol i les condicions meteorològiques). El sistema és molt més complex, per tant la xarxa no podrà predir tendències amb tanta precisió. Tot i així, al representar la predicció de la xarxa contra el consum, s'aprecia com la xarxa genera prediccions que segueixen de molt a prop a les mostres reals. Si bé no és perfecte, com es veu amb les discrepàncies considerables en segments de les prediccions 5, 6 i 7 de la selecció aleatòria (Figura 3.34), en general les dues línies coincideixen.

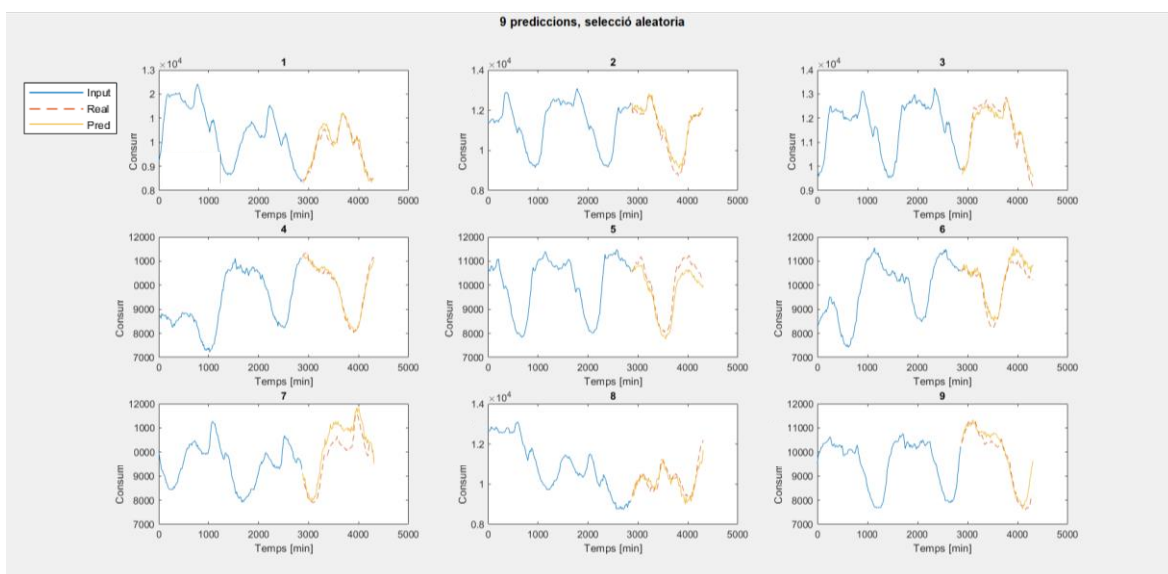


Figura 3.34 Prova 3\_1000: 9 prediccions de la xarxa amb 180 neurones a la capa 1

En la Figura 3.35 s'observa com a l'augmentar el número de neurones, la xarxa es va fent més i més precisa fins a arribar un punt (a partir de les 120 neurones) en que la precisió s'estabilitza. Per evitar l'overfitting, s'ha considerat com 180 a número orientatiu de ser el número adequat de neurones en una sola capa, degut a que és el que dona menor RMSE.




Figura 3.35 Prova 3\_1000: Evolució del RMSE en funció del número de neurones la xarxa

### 3.6.5 Etapa 3, prova 2000. Comparació entre funcions d'activació

Degut a que aquesta etapa està centrada en un sistema completament diferent a l'anterior, es totalment possible que la funció d'activació tansig sigui més adequada que la logsig que s'ha utilitzat fins aquest punt. Per descartar aquesta possibilitat, es va repetir la prova 2000 utilitzant la funció d'activació tansig. El resultat va ser el mateix que en l'etapa 2. Les xarxes amb funció d'activació tansig són generalment menys precises que les que utilitzen la funció logsig (Figura 3.36).




Figura 3.36 Prova 3\_2000: Comparació de precisió entre les xarxes amb funció d'activació logsig i tansig

### 3.6.6 Etapa 3, prova 4000. Eliminació del temps

En aquesta etapa la matriu input contenia, a més de les dades de consum d'energia, el dia de l'any de l'inici del bloc (del 1 al 366), així com l'hora d'inici del bloc en minuts (del 0 a 1425). Per comprovar que aquests dos indicadors són significatius, s'ha creat una xarxa amb 150 neurones, entrenada amb els dos indicadors, només amb l'indicador del dia, només l'indicador de l'hora, i sense cap indicador temporal. S'ha repetit el procés dos cops i s'ha calculat la mitjana dels diferents criteris d'avaluació (per reduir les discrepàncies que es creen en entrenar cada xarxa). A la Taula 3.11 es troben els resultats.

Taula 3.11 Prova 3\_4000: Paràmetres de la distribució d'errors entre la predicció i el target, amb o sense indicadors de temps

Xarxa	Mitjana	Desviació	% errors dintre el rang	MAE	RMSE
<b>Sencera</b>	1,75405	423,3865	25,79355	301,7266	423,39025
<b>Només hora del dia</b>	1,70085	426,79295	25,6295	303,7453	426,8017
<b>Només dia de l'any</b>	0,90495	433,0376	25,27205	308,6736	433,0552
<b>Cap indicador temporal</b>	0,37089	441,60235	24,81945	314,4904	441,60415

El que es pot apreciar en la taula es la deterioració de la precisió de la xarxa a mesura que se li extreuen els indicadors temporals. Hi ha una clara diferència entre el RMSE obtingut amb la informació del temps, i l'obtingut sense. La xarxa és més precisa amb la informació del temps. I té sentit, ja que és quelcom conegut que el consum d'energia es molt estacional, per tant qualsevol model que hagi de predir la càrrega a la xarxa ha de tenir en compte en quin dia de l'any està. El mateix passa amb l'hora, ja que no és consumeix el mateix de dia que durant la nit. Amb els resultats es pot concloure que l'hora del dia és lleugerament més significativa que el dia de l'any.

Tot i això, igual que es va veure amb la producció d'energia, el model sense la informació temporal segueix sent satisfactòriament precís. Els indicadors temporals poden ajudar a afinar la predicció, però l'històric de la mostra sempre serà el que tingui més pes a l'hora de predir el dia següent amb fiabilitat.

### **3.6.7 Etapa 3, prova 5000. Introducció del dia de la setmana**

És lògic pensar que el dia de la setmana afecta al consum global de la xarxa. En dies laborables, hi ha més activitat, les fabriques estan en marxa, etc. La demanda d'energia es superior. En els caps de setmana, hi ha menys indústria treballant i el consum energètic de la població és menor ja que la gent roman a casa.

Aquesta hipòtesis cal suportar-la amb les dades de les que es disposa. Per fer-ho, es va calcular la mitjana de les consumicions en funció del dia de la setmana. En altres paraules, es van ajuntar les dades en un set vectors de 96 mostres (una mostra cada 15 minuts), cada un sent representatiu de un dia de la setmana.

El gràfic de la Figura 3.37 confirma la hipòtesis. Mentre que els consums dels dies laborables són molt similars entre ells, hi ha una diferència clara respecte els del dissabte i diumenge.




Figura 3.37 Consum d'electricitat en funció del dia de la setmana

Per a introduir la informació del dia de la setmana a la xarxa hi ha diversos mètodes. Es tracta d'un propietat discreta i qualitativa, i es necessària codificar-la. Es pot pensar que codificar els dies del 1 al 7 serviria. I en realitat la xarxa sí que es capaç de treballar amb aquesta codificació. L'inconvenient que apareix és que la xarxa veuria la parella dilluns-dimarts com quelcom pròxim (ja que la diferència es del 1 al 2), mentre que la parella diumenge-dilluns es tractada com la més llunyana (del 7 al 1). Per a que la xarxa funcioni millor, cal que tracti tots els dies com iguals [24]. Per a fer això, s'afegeixen 7 nous factors binaris a l'input. D'aquesta manera, si es tracta d'un dimecres l'input tindrà els factors [0, 0, 1, 0, 0, 0, 0] dintre seu. Així, tots els dies de la setmana estan igualment diferenciats.

Cal notar que en les proves anteriors, en introduir el dia de l'any o l'hora del dia s'estava cometent l'error que s'acaba d'explicar. La diferència entre el dia 1 i el 2 de Gener és la mateixa que la del dia 31 de Desembre al 1 de Gener, però la xarxa veu com de l'últim dia al primer hi ha una diferència de 365 dies. Com ja s'ha mencionat, la xarxa pot superar aquest "error" (ja s'ha vist a les proves anteriors com els indicadors del temps són útils per millorar la precisió, encara que no estiguin òptimament codificats), però si es vol la màxima precisió s'hauria de tenir en compte. Però una cosa és introduir 7 nous indicadors per indicar el dia de la setmana, que incloure 365 per representar cada dia de l'any (o el que seria més precís, tenir 35040 indicadors binaris que indiquen dia i minut de la mostra). La xarxa seria massa complexa i no es justificaria l'augment innecessari de factors.

En l'estudi *Classification of Special Days in Short-Term Load Forecasting: The Spanish Case Study* [25], es va proposar una alternativa a aquesta codificació, seguint obtenint una

millora clara en la precisió sense tenir que afegir grans quantitats de variables. La solució proposada consisteix en la introducció d'una classificació dels dies en diversos paràmetres. Apart d'assignar el dia de la setmana i el mes, es van afegir diverses variables més fins arribar a 53 variables binaries per definir el tipus de dia (per exemple variables específiques per dies especials com Nadal i Setmana Santa). Es va arribar a la conclusió que aquesta classificació significava una millora dels models. Donat que la creació d'aquestes variables addicionals requereix d'un estudi intensiu dels patrons de consum previs, fet que queda fora de l'abast de l'objectiu d'aquesta etapa, per a aquesta prova només s'han introduït els set indicadors del dia de la setmana.

Taula 3.12 Disseny de la xarxa de la prova 3\_5000

<b>Nom xarxa</b>	E3P5000
<b>Inputs</b>	Dades de càrrega d'energia de dos dies dels anys 2014-2019
<b>Format Inputs</b>	[codificació dia de la setmana, temps any, temps dia, consum(t-(48*4-1)), consum(t-(48*4-2)),...consum(t)]
<b>Targets</b>	Dades de càrrega d'energia 2014-2019, del dia següent a l'input
<b>Format Targets</b>	[consum(t+1),consum(t+2),...,consum(t+24*4)]
<b>Algoritme d'entrenament</b>	Trainscg

Els resultats d'incloure aquestes variables addicionals van resultat molt positius. Mentre que el mínim RMSE aconseguit sense elles era aproximadament de 420, amb elles es va aconseguir arribar a reduir-lo fins a 300. A la Figura 3.38 es pot veure com la distribució d'errors és més compacta que en la prova 1000.




Figura 3.38 Prova 3\_5000: Histograma d'errors de la xarxa amb el dia de la setmana codificat. Xarxa amb un capa de 100 neurones



Però aquesta millora substancial no acaba aquí. Es va experimentar amb incloure una segona Hidden Layer i veure els efectes que tenia. A diferència de l'etapa 2, on la inclusió de capes addicionals provocava overfitting i un empitjorament general de la xarxa, en el cas de la predicció del consum el que succeeix es el contrari.

En la Figura 3.39 es poden veure els resultats d'aquesta millora. S'han inclòs les millors xarxes que s'han aconseguit. Tant en el cas on no s'inclouïa el dia de la setmana com en el que sí, l'addició d'una segona capa augmentava considerablement la precisió. La xarxa sense el dia de la setmana aconsegueix reduir el seu RMSE de 420 a 380, mentre que la xarxa amb els dies de la setmana té una reducció del RMSE de 299 a 273.




Figura 3.39 Resultats de la xarxa amb una estructura de 100 neurones a la capa 1 i 40 a la segona. A l'esquerra l'input no incloïa la codificació del dia, a la dreta sí. Ambdues mostren millors resultats que en els casos on no hi havia una segona capa.

Mirant un recull aleatori de 9 prediccions emprant aquesta última xarxa (Figura 3.40), es pot veure l'alta precisió de les prediccions al combinar tenir els dies de la setmana com a input i una segona capa. Segueix sense ser perfecte, com es pot veure sobretot en les prediccions 2 i 3, però la línia de predicció és capaç d'ajustar-se molt pròximament a la realitat.

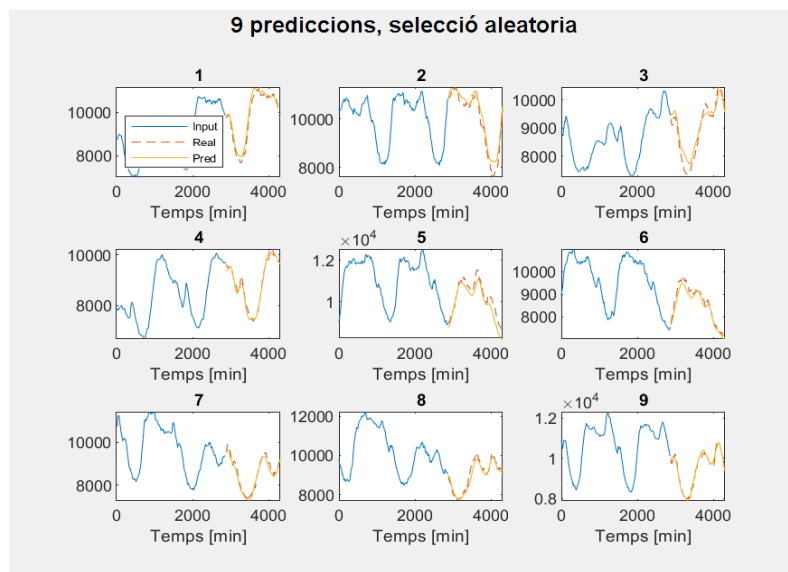


Figura 3.40 Recull aleatori de 9 prediccions emprant una xarxa que inclou els dies de la setmana com en l'input i amb una estructura 100-40 neurones en dues capes

### 3.7 Etapa 4: Obtenció del model de predicció del consum i de la irradiació final

#### 3.7.1 Objectiu de l'etapa

En les etapes 2 i 3, s'ha comprovat com efectivament es poden emprar xarxes neuronals per obtenir models de predicció tant com del consum com de la irradiació. Les etapes anteriors també han servit per refinar i optimitzar el procediment de creació de les xarxes. Amb el que s'ha après en les etapes anteriors, ara es procedeix a aplicar-ho al set de dades finals que s'utilitzaran per complir l'objectiu del treball d'obtenir un model que permeti gestionar el dèficit entre l'energia generada i la consumida.

La gestió del dèficit amb xarxes neuronals es pot fer de dues maneres. O bé es creen dos models diferents, un per la irradiació i l'altre pel consum, i un cop obtingudes les prediccions es fa una simple resta, o bé es crea una xarxa que tingui com a entrades informació tant de la irradiació com del consum, per que obtingui el dèficit directament. L'objectiu d'aquesta etapa és fer una comparació entre aquestes dues alternatives.

Per a realitzar l'objectiu d'aquesta etapa, primer cal obtenir dues xarxes independents que puguin fer la predicció tant de la càrrega com de la irradiació respectivament, i refinar-les fins a aconseguir el menor error possible. Un cop obtingudes, s'obté una tercera xarxa que directament faci la predicció del dèficit, i s'avaluarà quina és la millor opció.

Un altre objectiu addicional d'aquesta etapa final és estudiar la possibilitat d'utilitzar un model de predicció d'irradiació empíric enlloc de les xarxes neuronals. En cas de que el model empíric es demostrés més precís, per tal de gestionar el dèficit s'utilitzaria un model híbrid amb la xarxa del consum.

Al codificar les diferents proves, s'afegeix a la codificació "Irr" o "Cons" en funció de si es tracta de proves que utilitzen les dades d'Irradiació o les de Càrrega.

### **3.7.2 Preparació de les dades**

Els procediments preparació de les dades han estat idèntics als realitzats en les etapes anteriors. El mostratge de les dades original era de 5 minuts. Aquest període de mostra tant petit, combinat amb l'alta inestabilitat de les mostres, complicaria molt la tasca de trobar un bon model per elles. Per tant, es va tornar a delmar les dades per tenir un període de mostratge de 15 minuts. Això pal·liava els efectes de la inestabilitat, però tampoc els eliminava.

S'han tornat a agrupar les dades en conjunts de 48 hores pels inputs, i les 24 hores següents pels outputs. S'ha afegit l'hora del dia de la primera mostra com a informació temporal. Al tenir dades més limitades, no s'ha afegit la informació del dia de l'any per falta de dades d'altres anys.

Per la divisió en els conjunts training, validation i test s'ha emprat un compromís entre el mètode en que es va començar a realitzar inicialment (agafar un bloc de les últimes mostres com a test) i el que es va utilitzar a partir de l'etapa 2 (barrejar totes les mostres i agafar un percentatge d'aquestes com a test). El primer dona problemes si el últim bloc de dades conté alguna peculiaritat o existeix algun canvi de tendència, i no permet fer un testeig representatiu de diversos punts temporals. El segon no permet testear la xarxa amb un bloc continu de dades (es a dir, veure com de bé la xarxa preveu una setmana seguida sencera). El nou mètode de divisió és un punt mig entre aquests dos, i es pot veure a la Figura 3.41.




Figura 3.41 Divisió dels conjunts de Training, Validation i Testing

Per tal d'aconseguir testejar la xarxa amb mostres representatives que continguin bloc continus de dades, s'ha fet la divisió de manera que cada 28 dies, els primers 21 aniran al conjunt de training i validation (s'introduiran a la xarxa), i els altres 7 es separaran per a realitzar els tests un cop entrenada la xarxa.

### 3.7.3 Criteris d'avaluació de la xarxa

No s'han modificat els criteris respecte les proves anteriors. El RMSE segueix sent la mesura principal que es mira per tal de comparar dues xarxes, amb l'histograma, el performance plot i les prediccions aleatòries sent útils per fer les comparacions visualment.

### 3.7.4 Obtenció de la xarxa de predicció d'Irradiació

S'ha repetit el procediment de l'etapa 2, òbviament incloent-hi les optimitzacions que es van anar aprenen amb l'experiència, però generalment el procés és molt similar. L'única diferència ha resultat la decisió sobre si incloure la temperatura o no en l'input de la xarxa. En períodes de més irradiació solar, a l'estiu, la temperatura és superior, i en canvi en períodes de poca irradiació, a l'hivern, les temperatures són més baixes. Si no es pot introduir a la xarxa la informació del dia de l'any per falta de dades, donar-li la informació de la temperatura es una alternativa per a que almenys tingui una idea general de les estacions.

Es disposa del mateix nombre de mostres de temperatura que de irradiació, sent preses al mateix instant. Per no sobrecarregar la xarxa amb tants factors, per a aquesta primera prova es va incloure només dos indicadors de la temperatura, corresponents a les mitjanes de temperatura dels dos dies anteriors. No és un indicador perfecte (ja que per exemple no

dona informació d'inestabilitat meteorològica) , però s'ha decidit utilitzar aquest indicador senzill només per veure si s'ha d'estudiar més o no la inclusió de la temperatura en els càlculs.

Es van crear llavors dos tipus de xarxes, un amb aquests indicadors de la temperatura, l'altre sense, mitjançant el mètode iteratiu de les etapes anteriors. L'estructura d'aquestes xarxes es troba a la Taula 3.13

Taula 3.13 Disseny de la xarxa de la prova 4\_Irr

<b>Nom xarxa</b>	<b>E4_Irr</b>
<b>Inputs</b>	Dades d'Irradiació de dos dies, amb o sense els indicadors de temperatura
<b>Format Inputs</b>	[Indicadors temperatura (o no), minut dia, Irr(t-(48*4-1)), Irr(t-(48*4-2)),...,Irr(t)]
<b>Targets</b>	Dades d'Irradiació del dia següent a l'input
<b>Format Targets</b>	[Irr(t+1),Irr(t+2),...,Irr(t+24*4)]
<b>Algoritme d'entrenament</b>	Trainscg

Al realitzar el procés iteratiu, es van obtenir els diferents RMSE de cada xarxa. A la Figura 3.42 es veu una evolució dels errors a mesura que s'augmenta la mida de la capa. En els dos casos arriba un punt, cap a les 200 neurones, en que els errors s'estabilitzen. El que es pot veure a simple vista és la millora significativa que provoca la inclusió de la temperatura en la predicció, disminuint en 5 el RMSE.




Figura 3.42 Prova 4\_Irr: Comparativa de la xarxa amb informació de la temperatura i la xarxa sense informació de la temperatura

A la Figura 3.43 s'observen els resultats de la xarxa més precisa que s'ha aconseguit, amb 190 neurones a una capa. Com era d'esperar, la xarxa pot predir acuradament la tendència sinusoidal que té la irradiació, però en el moment que apareix inestabilitat, com es pot veure

en els sobtats salts que succeeixen en les línies vermelles de les prediccions 2, 3 i 4, la xarxa no funciona tant bé. L'histograma mostra una molt bona distribució dels errors pròxim al zero, que ajuda al baix error mitjà.

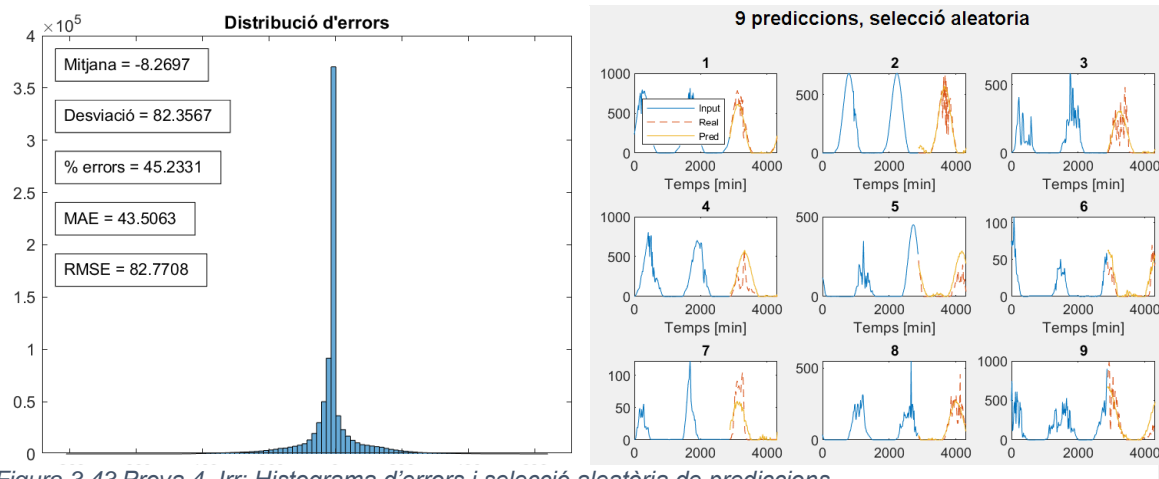


Figura 3.43 Prova 4\_Irr: Histograma d'errors i selecció aleatòria de prediccions

### 3.7.5 Comparació entre xarxes neuronals i el model teòric de predicció d'Irradiació

Per comprovar la robustesa de les xarxes neuronals en la predicció d'irradiació, s'ha decidit fer una comparació entre el model obtingut a l'apartat anterior, i un altre model teòric d'estimació d'irradiació.

El model escollit és el de l'article *Optimal management of energy in a standalone microgrid, with photovoltaic generation, short-term storage in a battery, and hydrogen production* [26]. Aquest article també fa un estudi de la gestió de micro-xarxes, incloent la inclusió de la previsió d'irradiació, però enlloc d'utilitzar xarxes neuronals utilitza un model empíric. Es va proporcionar el codi per a l'ús d'aquest model, inclòs a la carpeta "Model d'Irradiació Solar Teòric" de l'Annex.

Aquest model combina un model geomètric, que permet obtenir la Irradiació Extraterrestre. El model geomètric només té en compte la localització geogràfica de la placa, i la seva orientació respecte al Sol. Amb això, amb un seguit d'equacions que es poden trobar a l'article original, s'obté una estimació de la irradiació que rep la placa ignorant els afectes de l'atmosfera. El fet d'ignorar l'atmosfera fa que la irradiació calculada sigui superior a la que es mostreja, ja que en la realitat part de la irradiació és perd en entrar en contacte amb l'atmosfera i núvols.

Per a afegir aquesta atenuació, s'inclou un coeficient de terbolesa. Aquest coeficient agrupa part de la informació geomètrica de la placa amb la irradiació real mostrejada el dia anterior.

Aquest coeficient permet introduir al model informació de les condicions atmosfèriques del dia anterior, per tal de millorar l'eficàcia.

Es va fer la comparació entre els resultats obtinguts amb aquest model i els de la millor xarxa obtinguda en l'apartat anterior, realitzant la predicció amb els dos models dels dies que es van separar com el conjunt de test en l'obtenció de la xarxa (no s'inclouen els dies amb els que s'ha entrenat la xarxa ja que li oferiria un avantatge addicional). Com a indicador de la precisió, s'ha agafat el RMSE en ambdós casos. Les conclusions que s'han obtingut són:

- De mitjana, la xarxa ofereix més precisió que el model teòric, tenint uns errors mitjos de 70.5516 i 78.7509 kW/m<sup>2</sup> respectivament. Cal mencionar la discrepància entre aquest error de la xarxa i el que s'havia indicat a l'apartat 3.7.4 com a millor resultat de 82.77 kW/m<sup>2</sup>. La xarxa utilitzada és la mateixa. Aquesta diferència de 12 kW/m<sup>2</sup> prové de que el model teòric només pot fer prediccions de les 00:00h fins a 23.45h, dia a dia, a diferència de la xarxa que pot realitzar les prediccions de les següents 24h partint de qualsevol hora. Al fer la comparació amb el model, només s'han introduït a la xarxa aquelles entrades que corresponguessin a un bloc de mostres començant a mitjanit. La xarxa és més precisa en aquests casos que en la resta, resultant amb aquest 12 kW/m<sup>2</sup> d'error de menys.
- En el cas concret dels dies clars, és a dir quan no es produïen inestabilitats, el model teòric és més precís, sent el seu error mig 4.22 kW/m<sup>2</sup> inferior (61.1417 en el model teòric, 65.3675 en la xarxa). A la Figura 3.44 s'observa com el fet que els dos dies anteriors fossin inestables fa que la xarxa també predigui inestabilitat, però el model s'ajusta molt bé al dia clar real.




Figura 3.44 Resultats del dia 23

- En casos en que el dia anterior i el que s'ha de predir són molt diferents, la xarxa que conté informació dels dos dies previs pot acostar-se més a la realitat. En la Figura 3.45 es pot observar aquest comportament. El dia 54 va ser molt inestable, mentre que el 55 va ser clar. El model només té en compte el 55 i per tant preveu que el 56 també serà clar. La xarxa que “veu” la inestabilitat del dia 54 dona una predicció que ve a ser el punt mig entre els dies 54 i 55, que és més pròxima a la realitat del dia 56.




Figura 3.45 Resultats del dia 56



- Tot i que en aquest cas no succeeix, en una situació hipotètica en que hi hagués un obstacle entre la trajectòria del Sol i la placa, com per exemple un edifici, la xarxa neuronal pot aprendre com durant un interval de temps la irradiació sempre baixa, mentre que aquest model és incapaç d'incloure situacions d'aquest tipus.
- La inestabilitat freqüent que es produeix a la zona és un detriment per als dos models, però especialment per al model teòric, que està més pensat per a dies clars. Per tant, es pot concloure que, tot i que tenir inestabilitat dificulta qualsevol sistema de predicció, les xarxes neuronals donen més flexibilitat i robustesa enfront a prediccions més complexes.

### 3.7.6 Obtenció de la xarxa de predicció del consum

El consum, per la seva banda, va demostrar provocar més dificultats. El procediment d'obtenció de la xarxa va ser el mateix que en el de la Irradiació, sense incloure la temperatura.

*Taula 3.14 Disseny de la xarxa de la prova 4\_Cons*

<b>Nom xarxa</b>	E4_Cons
<b>Inputs</b>	Dades de consum de dos dies
<b>Format Inputs</b>	[minut dia, cons(t-(48*4-1)), cons(t-(48*4-2)),...cons(t)]
<b>Targets</b>	Dades de consum del dia següent a l'input
<b>Format Targets</b>	[cons(t+1),cons(t+2),...,cons(t+24*4)]
<b>Algoritme d'entrenament</b>	Trainscg

En la Figura 3.46 es troben els resultats del procés iteratiu de creació de xarxes. Com es pot veure, s'arriba a un mínim de RMSE al voltant de les 180 neurones i a partir d'aquest punt la performance empitjora.




Figura 3.46 Prova 4\_Cons: Evolució de la performance en funció del nombre de neurones

En la Figura 3.47 es pot veure el problema principal d'aquestes xarxes. La gran irregularitat que té el consum fa que la xarxa pugi més o menys ajustar la tendència de la càrrega a la xarxa, però és incapaç de predir quan succeiran els pics més pronunciats. Entre la poca disponibilitat de dades i l'elevada inestabilitat que tenen aquestes, és fa evident la gran dificultat d'obtenir un model precís.

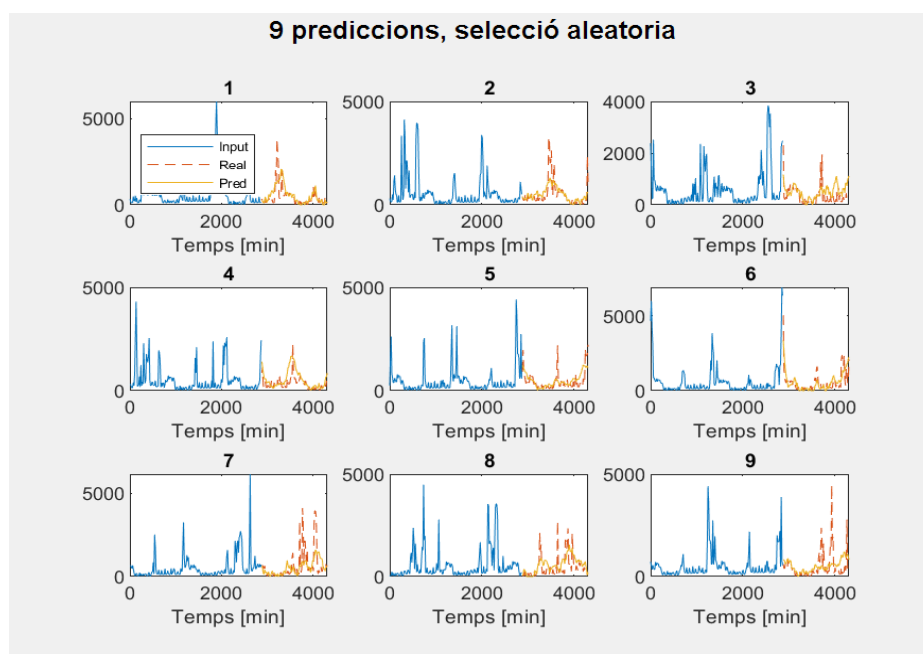


Figura 3.47 Prova 4\_Cons. Selecció aleatòria de prediccions de la prova, amb la xarxa de 190 neurones

S'havia de buscar maneres de refinar més el model. El que es va plantejar va ser incloure en el model el dia de la setmana, igual que es va fer en l'etapa 3. Al tenir menys dades, es va poder representar en 7 gràfics tots els dies de la setmana agrupats (és a dir, els 52 dilluns de l'any en un gràfic, els 52 dimarts de l'any en un altre, etc.). A la Figura 3.48 es troben aquests gràfics.




Figura 3.48 Representació del consum de tots els dies, agrupats per dia de la setmana. A l'es troba la mateixa imatge en apaïsat per a que es pugui veure millor.

En aquesta figura es veuen diferències clares entre el perfil de consum típic d'un dia laborable i el de un dia de cap de setmana. Si es té en ment de que les dades provenen d'un grup de cases familiars, no resulten sorprenents els perfils dels dies laborables, que mostren una rutina clàssica. El consum és mínim fins a les 7 del matí, quan els habitants es desperten. Passades les 8, el consum torna a baixar ja que els habitants estaran a la feina o a l'escola. A l'hora de dinar hi ha una pujada menys pronunciada, possiblement perquè no tota la gent que viu a les cases torna a casa per dinar, i a partir de les 16 és quan comença un període llarg de consum d'electricitat fins la nit. En canvi, en els dies de cap de setmana, el consum és més erràtic ja que no se segueix una rutina.

Veient que existeixen aquestes diferències, es va concloure que introduir en el model el dia de la setmana, amb 7 variables binàries, resultaria beneficiós. I, efectivament, al realitzar el procés iteratiu es va aconseguir trobar una xarxa de 130 neurones que minimitzava el RMSE fins a 572.3793, una reducció del 6.8% respecte el millor error que s'aconseguia sense incloure els indicadors del dia de la setmana. A la Figura 3.49 es troba una comparació entre l'histograma d'aquestes dues xarxes.




Figura 3.49 Prova 4\_Cons: Histograma d'errors de les xarxes amb millors resultats incloent el dia de la setmana (esquerra) i sense incloure el dia de la setmana (dreta)

### 3.7.7 Obtenció de la xarxa del dèficit

Finalment s'han obtingut les dues xarxes més precises que s'han pogut tant per la irradiació com per el consum. Aquestes s'anomenaran irr\_net i cons\_net (ambdues estan incloses a l'Annex). A la Taula 3.15 es troben les seves propietats:

Taula 3.15 Propietats de les xarxes Irr\_net i Cons\_net

Nom xarxa	Irr_net	Cons_net
<b>Inputs</b>	Dades de irradiació de dos dies	Dades de consum de dos dies
<b>Format Inputs</b>	[temperatura dia 1, temperatura dia 2, irr(t-(48*4-1)), irr(t-(48*4-2)),...irr(t)]	[codificació del dia de la setmana, minut dia, cons(t-(48*4-1)), cons(t-(48*4-2)),...cons(t)]
<b>Targets</b>	Dades de consum del dia següent a l'input	Dades de consum del dia següent a l'input
<b>Format Targets</b>	[irr(t+1),irr(t+2),...,irr(t+24*4)]	[cons(t+1),cons(t+2),...,cons(t+24*4)]
<b>Algoritme d'entrenament</b>	Trainscg	Trainscg
<b>Funció d'activació</b>	Logsig	Logsig
<b>RMSE en el conjunt de Test</b>	82.77 kW/m <sup>2</sup>	562.3793 kW

#### 3.7.7.1 Càlcul del dèficit

Es considerarà el dèficit com la quantitat d'electricitat que la micro-xarxa no pot auto-generar amb les plaques fotovoltaïques (PV), i que ha de recórrer a bateries, a un generador no renovable o a la xarxa principal per cobrir la demanda (Eq. 3.1). Un dèficit negatiu significa un excés de producció d'energia, que es pot emmagatzemar en les bateries o vendre a la xarxa principal.

$$P_{\text{dèficit}}(t) = P_{\text{consum}}(t) - P_{\text{PV}}(t) \quad (\text{Eq. 3.1})$$

Les mostres d'irradiació consisteixen dels  $\text{kW/m}^2$  que incideixen sobre les plaques solars. Per passar d'aquesta irradiació a corrent elèctric dintre la xarxa, cal multiplicar les mostres d'irradiació per l'àrea total dels panells solars (superfície  $S$  per número de panells  $N$ ) i pel rendiment de la pròpia placa i de l'inversor (Eq. 3.2). Aquests rendiments són afectats per factors externs com la temperatura exterior i el desgast, però per simplificar el model es consideraran constants. Per tant, es farà la simplificació que la irradiació  $I$  i l'electricitat produïda són directament proporcionals, per un factor que s'anomenarà  $\alpha$  (Eq. 3.3).

$$P_{PV}(t) = I(t) \cdot \eta_{\text{placa}} \cdot \eta_{\text{inversor}} \cdot S \cdot N \quad (\text{Eq. 3.2})$$

$$P_{PV}(t) = I(t) \cdot \alpha \quad (\text{Eq. 3.3})$$

Desafortunadament, no es disposa de la informació necessària per conèixer concretament aquest factor  $\alpha$ . Per a aproximar-lo, es va fer la suposició de que a l'instal·lar les plaques es va fer amb la intenció de cobrir totalment la demanda global anual. Per tant, els kWh totals produïts han de ser més grans o iguals que els kWh consumits al llarg de l'any. Per assegurar que la producció superarà la demanda, es fa la suposició addicional de que es va establir que la producció solar anual seria 1.2 vegades superior a la demanda anual. D'aquesta manera s'estableix l'Eq. 3.4

$$\int_{\text{anual}} I(t) \cdot \alpha = \int_{\text{anual}} P_{\text{consum}}(t) \cdot 1.2 \quad (\text{Eq. 3.4})$$

Amb la funció del Matlab trapz [27] es pot fer la integració numèrica de les series temporals d'irradiació i consum, en altres paraules es pot calcular l'àrea que deixen per sota en el gràfic (Figura 3.50). Amb les dues àrees calculades es resol directament l'Eq. 3.4 obtenint un factor de proporcionalitat  $\alpha$  de 6.2148. Aquest càlcul es pot trobar al fitxer calcul\_alfa.m de l'annex.




Figura 3.50 Representació de les àrees de la Irradiació i el Consum d'un segment de l'any

### 3.7.7.2 Model del dèficit amb dues xarxes independents

Amb les xarxes irr\_net i cons\_net i el factor  $\alpha$  ja obtinguts, es troba la precisió del model que utilitza les dues xarxes conjuntament. Es manté el conjunt de test que s'ha emprat durant tota l'etapa. A la Figura 3.51 es troben les precisions de les respectives xarxes individuals, i la precisió del dèficit




Figura 3.51 Distribució d'errors de la predicció de consum, producció i del dèficit (calculat amb dues xarxes independents)

Per tal d'entendre d'on prové l'augment tan pronunciat del RMSE al combinar les dues xarxes, s'ha realitzat un gràfic mirant l'error mig en funció de l'hora de la predicció. La Figura 3.52 permet veure quines són les franges horàries en les que les xarxes tenen pitjor precisió, degut a la inestabilitat que succeeix. Els errors de la producció es concentren durant la meitat del dia, ja que durant les hores de nit la inestabilitat meteorològica no afecta a la predicció d'irradiació (ja que serà nula). En canvi, els problemes de precisió més elevats en la demanda succeixen durant la nit, que és el moment on els ocupants de les cases

utilitzen més electricitat, però d'una manera més difícil de predir. Com que els errors de les dues xarxes es propaguen en els del dèficit al combinar-les, s'empitjora la precisió del dèficit.




Figura 3.52 Distribució dels errors de consum, producció i dèficit en funció de l'hora de la predicció

Tenint present aquest augment de l'error, s'arriba a un RMSE mínim de 775 kW combinant les dues xarxes més precises possibles. A la Figura 3.53 es troba un recull de prediccions fetes amb les dues xarxes. Es pot apreciar com la línia de la predicció (la groga) pot ajustar-se al perfil general de l'evolució del dèficit, però, al trobar-se amb pics molt pronunciats no és capaç d'anticipar-los. Era previsible que això passés, ja que succeïa el mateix en el moment de predir el consum individualment. Al ser aquests pics de tant curta durada i en un instant de temps que no és manté, la xarxa no pot col·locar-los en les seves prediccions.

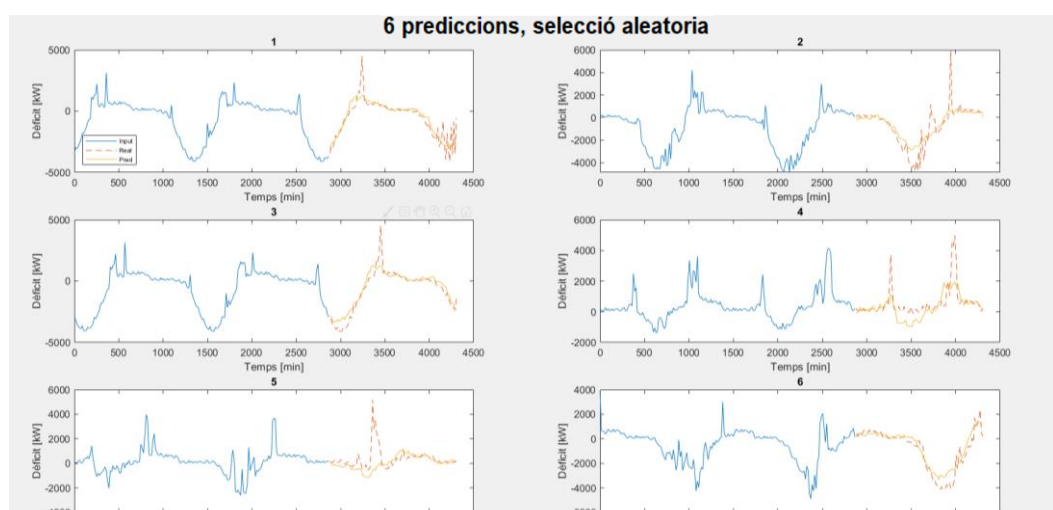


Figura 3.53 Prediccions aleatòries del conjunt de test ajuntant les de les xarxes irr\_net i cons\_net

### 3.7.7.3 Model del dèficit amb una xarxa conjunta

Per tal d'obtenir una xarxa conjunta, cal combinar les matrius input de la producció (s'ha multiplicat la irradiació pel factor de proporcionalitat  $\alpha$  directament) i de consum, ja utilitzades en els passos anteriors. Com a matriu target, s'ha realitzat directament la resta entre les dues matrius targets prèvies, per tenir les mostres del dèficit. Per tant, les matrius input i target tenen el format que es pot observar a la Figura 3.54. La xarxa, que s'anomenarà Def\_net, té les propietats indicades a la Taula 3.16.

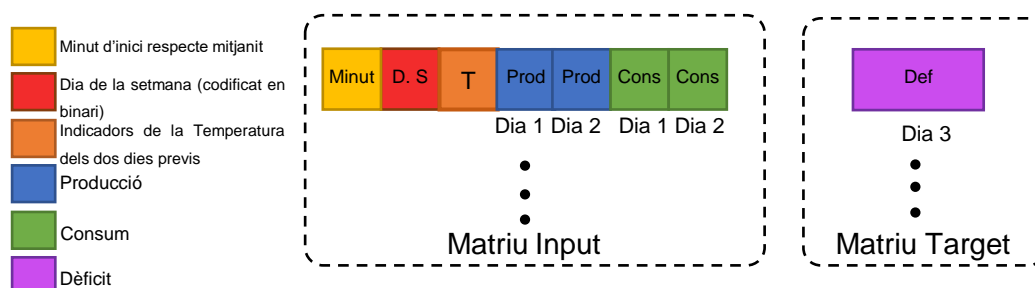


Figura 3.54 Format de les matrius input i target de la xarxa Def\_net

Taula 3.16 Propietats de la xarxa Def\_net

Nom xarxa	Def_net
<b>Inputs</b>	Dades de irradiació de dos dies
<b>Format Inputs</b>	[codificació del dia de la setmana, minut dia, temperatura dia 1, temperatura dia 2, irr(t-(48*4-1)), irr(t-(48*4-2)),...,irr(t), cons(t-(48*4-1)), cons(t-(48*4-2)),...,cons(t)]
<b>Targets</b>	Dades del dèficit del dia següent a l'input
<b>Format Targets</b>	[def(t+1),def(t+2),...,def(t+24*4)]
<b>Algorisme d'entrenament</b>	Trainscg
<b>Funció d'activació</b>	Logsig

A l'afegir indicadors addicionals a la xarxa, cal que aquests siguin significatius respecte el sistema a analitzar. Afegir indicadors innecessaris és un detriment per la xarxa, que intenta ajustar les prediccions en base a entrades que no són significatives, afegint soroll addicional a les respostes. En aquest cas, s'ha demostrat com tots els indicadors afegits dintre la matriu Input (Minut del dia, dia de la setmana, temperatura) significaven un augment de la precisió al desenvolupar les xarxes individuals. La matriu target conté una combinació lineal respecte les dues matrius targets que es tenien anteriorment, per tant en un principi hauria de semblar que els indicadors significatius en les xarxes individuals també ho haurien de ser en la conjunta.



No només això, sinó que al combinar tots els indicadors, hi ha la possibilitat que la xarxa trobi correlacions que li permetin millorar la precisió. Possibles correlacions podrien ser com la temperatura pot influir en el consum, o el fet que sigui un dia de pluja (és a dir amb menys irradiació) significa que els habitants es queden a casa i augmenta la demanda. Amb la matriu conjunta es vol comprovar si resulta beneficiós ajuntar tots els indicadors, o si per el contrari és més eficient fer dues xarxes especialitzades i ajuntar el resultat en un procés de post processat.

A la Figura 3.55 es poden veure els resultats del procés iteratiu d'obtenció de les xarxes amb una sola capa. La conclusió és evident, i és que la precisió amb la xarxa conjunta no s'acosta a la que s'obtenia amb dues xarxes especialitzades. L'error mínim que s'ha aconseguit és 812 kW, casi 40 kW per sobre del valor objectiu de 775 kW. A la Figura 3.56 s'observa com l'histograma d'errors de la xarxa def\_net (en taronja) és més ampli, i com l'histograma d'errors del model amb dues xarxes (en blau) està més concentrat pròxim al zero.




Figura 3.55 Evolució de la precisió de la xarxa Def\_net en funció del número de neurones




Figura 3.56 Comparativa de la distribució dels errors entre els dos models

Intents de millorar la qualitat de la xarxa amb la inclusió de capes addicionals no van resultar exitosos. Es van provar diverses combinacions de nombre de neurones en les dues capes, i la gran majoria provocaven una disminució de la precisió degut a l'overfitting. Algunes combinacions si que s'acostaven al nivell de precisió dels casos amb una sola capa, com la combinació de 140-100 neurones que comportava un error de 822 kW (Figura 3.57), però mai no superaven mai la qualitat dels models més simples d'una sola capa.




Figura 3.57 Histograma d'errors de la combinació de 140 neurones a la capa 1 i 100 a la capa 2.

Si s'observen les prediccions aleatòries dels dos models a la Figura 3.58, no s'aprecien gaires diferències. A simple vista no es pot determinar quina resulta més precisa, ja que

ambdós models mostren els mateixos problemes a l'hora de preveure els períodes curts on la demanda fa un pic. La diferència en precisions és difícil de veure a ull nu, però gràcies a l'histograma es pot saber que la línia vermella del model amb dues xarxes s'ajusta més a la realitat que la groga del model amb def\_net.

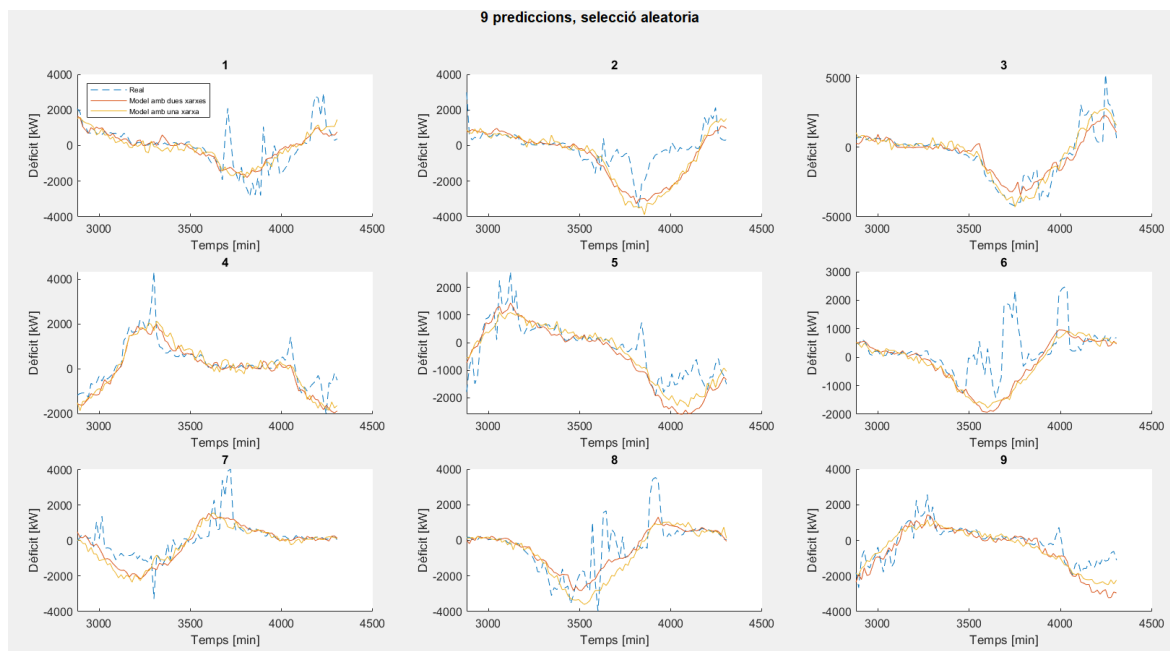


Figura 3.58 Recull de prediccions del conjunt de test, comparant entre els dos models

Amb aquests resultats, es pot concloure que és millor l'ús de diverses xarxes especialitzades enlloc d'una global. Els beneficis que poden significar hipotètiques correlacions entre els diversos factors poden no ser suficients per contrarestar l'existència de soroll addicional que se li introdueix a la xarxa. A l'introduir a la xarxa tots els indicadors junts, aquesta no pot diferenciar entre quins corresponen a irradiació i quins a consum. Això provoca que la xarxa trobi patrons on no en hi ha. Aquest fet queda exacerbat per la manca de dades que ha afectat a tota l'etapa.

Un altre avantatge que comporta tenir xarxes individualitzades es la possibilitat de particularització de les xarxes. Cada sistema al que se li aplica una xarxa neuronal té les seves particularitats, i es necessari que cada xarxa estigui adaptada única i exclusivament al seu sistema per tal de tenir la millor qualitat. Una xarxa pot aprendre d'aquestes particularitats, però si s'intenta estudiar alhora dos sistemes, les peculiaritats de un poden ser interpretades erròniament per la xarxa i aplicades a l'altra, donant pitjors resultats. Les xarxes poden requerir de funcions d'activació diferents. Si cal fer un procés de post-processat de les prediccions (com per exemple posar llindars màxims i mínims si aquests

són coneguts, per evitar que la xarxa faci prediccions fora d'ells), es pot aplicar a totes les dades, no només a la combinació de elles.

### 3.7.8 Model final

Finalment, el model final desenvolupat per la instal·lació de Lidenberg consisteix en dues xarxes específiques, una per la irradiació i una altra per la demanda. En obtenir les prediccions de cada una d'elles, es combinen per a obtenir una mesura del dèficit.

El model obtingut és capaç d'ajustar-se a la tendència general que té el dèficit, amb un RMSE total de 775 kW. La principal limitació que té és que és vulnerable als pics, sobretot els de demanda, degut a la seva curta durada i imprevisibilitat.

El model té espai per millorar en diverses àrees. La més important, degut a com afecta al desenvolupament de les xarxes neuronals, és la falta de dades. Per a obtenir un model més complet, que tingui en compte factors com les estacions de l'any, és necessari la introducció de mostres d'un interval de temps de diversos anys. En el moment de realitzar la implementació es recomanaria establir uns criteris de manteniment del model, de manera que un cop ha crescut la base de dades amb la que les xarxes es poden entrenar, s'actualitzin repetint el procés iteratiu realitzat en aquest treball, obtenint un model amb més refinat gràcies a l'augment de les dades. Per altra banda, el factor de proporcionalitat  $\alpha$  obtingut ha servit per a poder fer una aproximació de la producció elèctrica, però no és completament fidel a la realitat. Per tal de tenir un model més robust, seria millor que enlloc de tenir mostres d'irradiació, la xarxa s'alimentés directament amb la potència que surt dels inversors.

La implementació d'aquest model predictiu dintre del sistema de control de la micro-xarxa queda fora de l'abast d'aquest treball. Això inclou la manera en que el sistema interpreta les prediccions i les decisions que prendria en funció d'elles. De cara al manteniment d'aquest model, utilitzar dues xarxes enlloc d'una comporta la necessitat de que cada cop que es vulgui actualitzar el model (per exemple quan hi hagi noves dades disponibles), sigui necessari realitzar el procés iteratiu fins trobar el model òptim dos cops, fet que duplica la càrrega de treball.

S'ha inclòs aquest model en la funció `model_final.m`, que es pot trobar a l'Annex. Aquesta funció permet l'execució del model final, retornant la predicció d'irradiació, consum i dèficit de les pròximes 24h partint de les entrades corresponents.

## 4. Impacte ambiental

Part del motiu pel qual es va triar l'ús de dades de producció d'energia solar en aquest treball va ser perquè se li ha donat importància a la protecció del medi ambient. Per tant, s'ha volgut minimitzar l'impacte ambiental produït en la realització del projecte.

S'ha eliminat l'ús del paper, establint comunicació amb el tutor del treball i les diferents correccions via digital. No hi ha hagut necessitat de l'ús de cap material addicional. Per tant, tot l'impacte del projecte prové de l'energia utilitzada en el desenvolupament de la xarxa i en l'elaboració de la memòria.

Durant tota la duració del projecte s'ha utilitzat un portàtil *Lenovo Legion*. Durant les diferents etapes, per tal de realitzar el procés iteratiu d'obtenció de les xarxes era necessari deixar el programa de Matlab treballant durant períodes de temps extensos, de diverses hores. Si s'inclouen els intents fallits i el temps dedicat a la programació de les pròpies funcions, més el temps de redacció de la memòria, l'ordinador ha romàs encès durant una quantitat d'hores considerables. No és té el nombre exacte, però s'ha fet una estimació de 250 hores (corresponents a unes 20 hores a la setmana de mitjana des de que es va començar a fer un ús intensiu del procés iteratiu)

Segons les especificacions donades pel fabricant, aquest té un consum mitjà de 150.54 W. És possible que al deixar l'ordinador calculant durant diverses hores, fent un ús més extensiu de la memòria de l'ordinador, aquest consum fos més gran, però per l'altra banda en aquests casos la pantalla romanía apagada, baixant el consum. Tenint present això, s'agafa aquest consum mitjà com a referència pel càlcul de l'impacte ambiental.

Amb el factor de consum per hora i el nombre d'hores estimades d'ús, es pot calcular l'emissió de CO<sub>2</sub> que ha requerit aquest projecte. A la Taula 4.1 es troben les emissions de CO<sub>2</sub> provinent de diferents fonts en la generació d'energia d'Espanya (dades extretes de Red Eléctrica de España, [28]). Aquests paràmetres d'emissió són els d'Espanya en general, però es considerarà que el factor d'emissió de CO<sub>2</sub> mitjà del 2019 de 0.201 tones de CO<sub>2</sub> per MWh en els càlculs del consum particular d'aquest projecte.

Taula 4.1 Emissions de CO<sub>2</sub> associades a la generació mensual nacional. Font [28]

Fuente	Ene.	Feb.	Mar.	Abr.	2019
Carbón	3.148.919	2.306.342	931.513	819.323	7.206.097
Fuel + Gas	406.774	375.396	382.902	376.284	1.541.356
Ciclo combinado	1.356.348	1.063.637	956.970	1.180.349	4.557.304
Térmica no renovable/Cogeneración y resto/Cogeneración	984.099	885.626	959.125	921.773	3.750.623
Residuos no renovables	49.609	45.144	50.976	45.421	191.150
Emissiones (tCO <sub>2</sub> )	<b>5.945.749</b>	<b>4.676.145</b>	<b>3.281.486</b>	<b>3.343.151</b>	<b>17.246.531</b>
Factor de emision de CO <sub>2</sub> mig (tCO <sub>2</sub> /MWh)	<b>0,242</b>	<b>0,227</b>	<b>0,157</b>	<b>0,169</b>	<b>0,201</b>

Amb totes aquestes dades ja es pot realitzar la simple operació (Eq. 4.1) per obtenir les emissions de CO<sub>2</sub> durant aquest treball, obtenint un resultat de 37.635 kWh consumits, que corresponen a 7.6 kilograms de CO<sub>2</sub> emesos a l'atmosfera en la realització d'aquest treball

$$250 \text{ hores de consum} * 150.54 \cdot 10^{-6} \text{ MW} \cdot 201 \frac{\text{kg CO}_2}{\text{MWh}} = 7.6 \text{ kg CO}_2 \quad (\text{Eq. 4.1})$$

## 4.1 Beneficis ambientals

A part de l'impacte ambiental que ha requerit l'elaboració d'aquest projecte, cal mencionar els beneficis que la possible aplicació d'un sistema de predicció de producció i consum d'electricitat basat en xarxes neuronals en la gestió de la micro-xarxa tindria.

Per una banda, l'objectiu de tots els sistemes de control de la xarxa és treballar en tot moment en el punt més òptim. Tenir informació precisa de les necessitats de la xarxa en les pròximes hores permetrà una millor coordinació i optimització del sistema, evitant redundàncies i reduint el consum que provingui de les fonts no renovables o de la xarxa principal.

Per l'altre banda, el sol fet que els sistemes de control de les micro-xarxes són cada cop més i més sofisticats permet reduir els costos globals d'aquestes micro-xarxes, fent-les una inversió més atractiva. Això ajuda a fomentar l'ús de fonts d'energia renovables i a la reducció d'emissions de gasos d'efecte hivernacle.

El sistema de predicció basat en xarxes neuronals és només una peça dintre del complex mecanisme que és una micro-xarxa. El model donarà informació a la resta del sistema, i en coordinació amb els tres nivells de control explicat en el capítol 2.1 es prendran les decisions pertinents. Tenint en compte que només s'ha pogut disposar de les mostres de demanda i irradiació del sistema, i que l'estudi global de la micro-xarxa i el seu

funcionament queda fora de l'abast del treball, no es pot quantificar el benefici exacte que permetria la inclusió de la xarxa neuronal. Però sí que es pot afirmar que la inclusió de prediccions precises gràcies a la xarxa neuronal en el sistema permetrà una gestió de l'energia més òptima, i per tant més respectuosa amb el medi ambient.

## 5. Estudi econòmic

Els costos d'aquest treball han sigut escassos, degut a la naturalesa del projecte. Al no haver de fabricar cap producte ni realitzar cap instal·lació, els costos deriven únicament dels necessaris per al desenvolupament de la xarxa. A la Taula 5.1 estan indicats aquests costos.

*Taula 5.1 Costos del projecte*

	Quantitat	Preu unitari	Cost final
Llicència de Matlab	1	0 € (Llicència UPC) *800 €/any (Standard)	0 €
Ús d'energia	37.635 kWh	0.12 €/kWh	4.52 €
Hores dedicades	360 hores	20 €/Hora	7200 €
<b>Cost Total</b>			<b>7204.52€</b>

El Matlab ha estat l'eina utilitzada, i una llicència pot resultar costosa. La llicència estàndard per un any de Matlab costa 800 €. Per sort, la UPC té establert un conveni que dona accés gratuït al Matlab als estudiants de la universitat. Els mòduls addicionals de Matlab utilitzats també estaven inclosos, sense cost addicional.

La mètrica del consum d'energia s'ha explicat en el capítol anterior. El preu per kWh no és quelcom constant, però s'ha simplificat i pel càlcul del preu per kWh s'ha establert un preu de 0.12 €/kWh, basats en el preu mitjà de l'empresa Endesa pel 2019 [29].

En quant a les hores dedicades, s'ha fet una estimació de les hores emprades tant en crear les diferents funcions del Matlab i realitzant proves activament (és a dir, que s'estava en front l'ordinador). No s'han inclòs les hores en que es deixava l'ordinador en marxa realitzant el procés iteratiu, ja que no requerien de supervisió humana. La xifra d'hores dedicades es d'aproximadament 360 hores, les corresponents als 12 crèdits assignats al TFG dins el Grau en Enginyeria de Tecnologies Industrials, i s'ha aproximat un sou de 20€/hora per a l'enginyer que ha desenvolupat el projecte.

Igual que en l'estudi d'impacte ambiental, el fet de que no es té accés a la resta del sistema de control d'una micro-xarxa impedeix realitzar un estudi econòmic complet. Existeix el cost

addicional de la possible integració del model predictiu dintre el sistema que no es pot calcular, ja que no es té disponible la resta del sistema. Idealment també existiria un procés d'actualització periòdic per tal d'entrenar la xarxa amb més i més dades, per refinar encara més el model. Aquest procés requeriria de certa supervisió i comportaria un cost, però al millorar la qualitat del model també hi hauria un benefici.

De la mateixa manera, l'estalvi que pot generar la informació addicional provenint de les prediccions de la xarxa depèn de les decisions preses per tots els components del sistema. Les prediccions fiables de la xarxa permeten que el sistema tingui més informació per tal d'arribar en el punt de funcionament òptim, però aquesta eficàcia, i l'estalvi concret que pot representar, prové de la qualitat del conjunt del sistema, no únicament del model de predicció.



## Conclusions

Predir el futur no es una tasca fàcil. Fins i tot la irradiació rebuda, que depèn d'un fenomen tant constant com la sortida del Sol pateix irregularitats quan entra en joc la incertesa de la climatologia. Els meteoròlegs treballen amb grans quantitats de dades, provinents de centenars de fonts diferents, i fins i tot així no són infal·libles. De la mateixa manera, el consum d'energia de la població és erràtic, i depèn d'una llista inesgotable de factors. Amb aquest fet en ment, pensar que amb només amb les respectives dades històriques de irradiació i consum es podria complir l'objectiu marcat a l'inici del treball podria semblar quelcom inassolible.

Aquest treball ha demostrat com les xarxes neuronals ofereixen la flexibilitat per a poder trobar tendències i patrons que permeten anticipar-se al futur. En les etapes 2 i 3 s'ha demostrat que amb dades suficients i un bon entrenament, les xarxes neuronals poden ser utilitzades per l'obtenció de prediccions amb una precisió elevada. Aquestes dues etapes han estat clau a l'hora de refinar el procés de desenvolupament de les xarxes, havent estat utilitzades per a l'experimentació per establir els procediments i criteris a seguir a l'etapa final. Entre les conclusions obtingudes després d'aquestes fases experimentals, en destaquen:

- S'ha automatitzat el procés iteratiu, de manera que la creació de noves xarxes resulta més àgil.
- S'han establert uns criteris fixes de comparació entre xarxes. S'ha determinat l'ús de l'arrel de l'error quadràtic mig (RMSE) com la mesura de precisió més efectiva. L'ús d'histogrames d'errors per veure la distribució dels errors permet observar si es produeixen tendències positives o negatives, que permet detectar possibles problemes en la selecció dels conjunts de training, validation i testing. L'ús d'un recull de prediccions aleatòries permet fer un estudi visual bàsic de les sortides de la xarxa.
- La divisió final del conjunt de test consistint en l'última setmana de cada mes permet un tenir un conjunt de test que alhora sigui representatiu de totes les dades però també comprovi l'eficàcia de la xarxa enfront a mostres d'interval de temps separats dels utilitzats pel seu entrenament.
- S'ha establert la superioritat de la funció d'activació logsig respecte tansig en l'estudi tant de la demanda com de la irradiació.
- En l'etapa 3 s'ha vist com la consideració de factors addicionals com són els dies de la setmana és important a l'hora d'obtenir millors resultats.

Amb els coneixements adquirits en les etapes 2 i 3, es va procedir a l'obtenció del model final. No obstant, és innegable que la qualitat del model final no és del tot satisfactòria. Les dades de la micro-xarxa d'Alemanya oferien la possibilitat d'aplicar els coneixements sobre xarxes neuronals adquirits durant les primeres etapes en una situació real, que ajuntés producció solar i demanda alhora. Però també va significar entrebancs addicionals.

Primer de tot, la disponibilitat de només un interval d'un any de mostres era un gran detriment pel desenvolupament de les xarxes. Al comparar amb els bons resultats de les etapes 2 i 3 queda demostrada la importància de tenir una gran quantitat de mostres per tal de que el model sigui robust. El model final no té en compte factors significatius com les estacions o si es tracta d'un dia festiu o no, degut a que no hi havia repetibilitat en les mostres.

L'altre gran entrebanc ha estat la gran variabilitat de les dades, major a la vista en les etapes anteriors. L'existència de pics pronunciats en el consum i la poca quantitat de dies clars fa que una predicció exacta sigui impossible. Comparant amb els resultats de precisió del model teòric, s'ha demostrat que, tot i que aquesta variabilitat serà un detriment per tot model predictiu, el model amb xarxa neuronal ofereix una alternativa superior a models tradicionals.

El fet de voler estudiar el dèficit va requerir de realitzar estimacions addicionals a l'haver d'aproximar un factor de proporcionalitat que en la realitat no és constant. També va requerir realitzar un estudi respecte quina via era la que obtenia un millor model, la creació de xarxes independents especialitzades, o obtenir una xarxa única agrupant totes les dades alhora. Els resultats van demostrar com l'especialització permet a les xarxes tenir el millor rendiment.

Encara que l'error final obtingut no s'ha reduït tant com hauria estat ideal, els avantatges que el model basat en xarxes neuronals ofereix al sistema de control van més enllà del bon nivell de precisió que ofereix. El model creat permet fer una predicció de les pròximes 24 hores en qualsevol moment, simplement entrant les mostres dels últims dos dies. Això permet una immediatesa en les prediccions, quelcom que models teòrics no inclouen. Gran inestabilitat afecta negativament a qualsevol model, però aquesta immediatesa permet que en dies més inestables es tinguin prediccions actualitzades cada 15 minuts, enlloc de tenir només una predicció al dia com en el cas del model teòric emprat a l'etapa 4.

L'altre gran avantatge és que gracies a la naturalesa pròpia de les xarxes neuronals, hi ha la possibilitat d'aconseguir una millora contínua del model. No només perquè la xarxa té més informació per al seu entrenament, sinó també perquè l'inconvenient de la falta de dades a la llarga desapareix, de manera que es podrien incloure els indicadors que no s'han pogut fer-ho anteriorment.

Es pot concloure que s'ha complert l'objectiu del treball. El model finalment obtingut podria implementar-se dintre un sistema de control d'una micro-xarxa, permetent una gestió d'aquesta més eficient i òptima. Aquest model permet que es sotmeti a renovacions periòdiques, permetent la introducció de més dades i millorant la seva qualitat, reduint els inconvenients inicials que aquest té.

## Bibliografia

- [1] MENG, L. et al *Microgrid supervisory controllers and energy management systems: A literature review. Renewable and Sustainable Energy Reviews* 60. 2016.
- [2] BLASCO, F. *Cálculo horas Sol pico*. 2013. [<http://calculationsolar.com/blog/>, 13 de Maig de 2019]
- [3] TWENERGY, *¿Cómo funciona la energía solar fotovoltaica?* 2012. [<https://twenergy.com/a/como-funciona-la-energia-solar-fotovoltaica-339>, 13 de Maig de 2019]
- [4] SHAHAN, Z. *Sunpower Panels Awarded Guinness World Record*. 2011. [<https://www.reuters.com/article/idUS110444863620110620>, 15 de Maig de 2019]
- [5] JIACONDA, A *A Concise History of Neural Networks*. 2016. [<https://towardsdatascience.com/a-concise-history-of-neural-networks-2070655d3fec>, 16 d'Abril de 2019]
- [6] KURENKOV, A. *A 'Brief' History of Neural Nets and Deep Learning*, 2015. [<http://www.andreykurenkov.com/writing/ai/a-brief-history-of-neural-nets-and-deep-learning/>, 16 d'Abril de 2019]
- [7] NEW YORK TIMES, *NEW NAVY DEVICE LEARNS BY DOING; Psychologist Shows Embryo of Computer Designed to Read and Grow Wiser*. 8 de Juliol de 1958
- [8] MINSKY, M i PAPERT, S. *Perceptrons. An Introduction to Computational Geometry* 1969
- [9] WERBOS, P. *Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences. PhD thesis*. Harvard University, Cambridge, 1974.
- [10] ISAKSSON, E. i CONDE M. *Solar Power Forecasting with Machine Learning Techniques*. Estocolm, Suècia, 2018
- [11] BENITEZ, J.M.; CASTRO, J.L. i REQUENA, I. *Are artificial neural networks black boxes? IEEE Transactions on Neural Networks*. Vol:8(5), 1997)

- [12] SINGH WALIA, A. *Activation functions and it's types- Which is better?* 2017. [<https://towardsdatascience.com/activation-functions-and-its-types-which-is-better-a9a5310cc8f>, 15 de Maig de 2019]
- [13] DOROFKI, M. et al, *Comparison of Artificial Neural Network Transfer Functions Abilities to Simulate Extreme Runoff Data. 2012 International Conference on Environment, Energy and Biotechnology* Vol:33, 2012
- [14] SHARA, T. *Train, Validation and Test Sets.* 2017. [<https://tarangshah.com/blog/2017-12-03/train-validation-and-test-sets/>, 15 d'Abril de 2019]
- [15] CÖMERT, Z i KOCAMAZ, A.F. *A study of artificial neural network training algorithms for classification of cardiotocography signals, Bitlis Eren University Journal of Science and Technology.* Vol:7(2), 2017, p-96
- [16] THE MATHWORKS, Inc. *Conjugate Gradient Algorithms.* 2015. [<http://matlab.izmiran.ru/help/toolbox/nnet/backpr59.html>, 15 d'Abril de 2019]
- [17] MATHWORKS. *Documentació funció plotperform del Matlab.* [<https://es.mathworks.com/help/deeplearning/ref/plotperform.html>, Febrer de 2019]
- [18] Bhande, A. *What is underfitting and overfitting in machine learning and how to deal with it.* 2018. [<https://medium.com/greyatom/what-is-underfitting-and-overfitting-in-machine-learning-and-how-to-deal-with-it-6803a989c76>, 15 d'Abril de 2019]
- [19] MATHWORKS. *Deep Learning Toolbox.* [<https://es.mathworks.com/products/deep-learning.html>, Febrer de 2019]
- [20] DESERT KNOWLEDGE AUSTRALIA SOLAR CENTRE. Alice Springs. [<http://dkasolarcentre.com.au/historical-data/download>, Març de 2019]
- [21] ELIA. *Grid Data.* [<https://www.elia.be/en/grid-data/data-download>, Abril 2019]
- [22] SANGWONGWANICH, A. ; ZURMÜHLEN, S. ; ANGENENDT, G. ; YANG, Y. ; SÉRA, D. ; SAUER, D.U. i BLÅBJERG, F. *Reliability Assessment of PV Inverters with Battery Systems Considering PV SelfConsumption and Battery Sizing. Proceedings of the IEEE Energy Conversion Congress and Exposition.* 2018
- [23] MATHWORKS. *Documentació funció decimate del Matlab.*

- [<https://es.mathworks.com/help/signal/ref/decimate.html>, Març 2019]
- [24] OEPAS DOST. *Optimal construction of day feature in neural networks*. 2014  
[<https://stats.stackexchange.com/questions/126230/optimal-construction-of-day-feature-in-neural-networks>, 20 de Març de 2019]
- [25] LÓPEZ, M. ; SANS, C. ; VALERO, S. i SENABRE, C. *Classification of Special Days in Short-Term Load Forecasting: The Spanish Case Study*. *Energies* 2019, Vol:12(7), 1253.
- [26] CECILIA, A ; CARROQUINO, J. ; RODA, V. ; COSTA-CASTELLÓ, R. i BARRERAS, F. *Optimal management of energy in a standalone microgrid, with photovoltaic generation, short-term storage in a battery, and hydrogen production*. *Energies*. 2019
- [27] MATHWORKS. *Documentació de la funció trapz del Matlab*.  
[<https://es.mathworks.com/help/matlab/ref/trapz.html>, 1 de Juny 2019]
- [28] RED ELÉCTRICA DE ESPAÑA. *Series estadísticas nacionales*.  
[<https://www.ree.es/es/estadisticas-del-sistema-electrico-espanol/series-estadisticas/series-estadisticas-nacionales>, 23 de Maig de 2019]
- [29] SELECTRA. *¿Cuál es el coste del kWh en España 2019? Precio de Luz Hoy y Tarifas*.  
[<https://comparadorluz.com/tarifas/precio-kwh>, 10 de Juny de 2019]

## Annex

### Fitxers complementaris

Acompanyant a aquesta memòria hi ha una carpeta (comprimida en format .zip) que inclou els fitxers als quals s'ha fet referència al llarg del treball. En aquest capítol es fa una breu explicació de cada un d'ells. Dintre la carpeta hi ha el fitxer `read_me.txt` amb la mateixa informació.

Continguts de l'Annex:

- `Entrenament_xarxes_codi_base.m`
- `calcul_alfa.m`
- `model_final.m`
- `irr_net` i `cons_net`
- `def_net`
- Carpeta "Dades"
- Carpeta "Model d'Irradiació Solar Teòric"

---

**entrenament\_xarxes\_codi\_base.m:** es tracta del fitxer amb el codi base pel desenvolupament de les xarxes amb el procés iteratiu explicat el capítol 3.1.2. Com que la base requereix de petites modificacions en funció del conjunt de dades d'entrada, s'ha adaptat el fitxer per a les dades de consum de l'etapa 4. Tot i això, amb els canvis pertinents es pot adaptar el codi a obtenir xarxes de qualsevol sèrie temporal. Dintre del codi hi ha comentaris especificant que realitza cada línia.

**calcul\_alfa.m:** Segons el procediment explicat en el capítol 3.7.7.1, Càlcul del dèficit, aquest fitxer troba el factor de proporcionalitat alfa

**model\_final.m:** Fitxer amb la funció que empra el model per realitzar prediccions. Retorna tant la predicció del dèficit conjunta com les prediccions per separat de irradiació i consum. Per a utilitzar la funció, cal cridar-la de la següent forma:

```
[pred_def,pred_irr,pred_cons]=model_final(minut_dia,dia_setmana,temperatures,irr,cons)
```

`Model_final` executa les dues xarxes `irr_net` i `cons_net` i retorna les prediccions corresponents, més la predicció del dèficit que les combina.

**Inputs:**

- Minut\_dia --> minut del dia des de les 00:00h. Del 0 a 1440.
- dia de la setmana --> del 1 (dilluns) al 7 (diumenge)
- temperatures --> [T1,T2]= temperatures mitges dels últims dos dies, en °C
- irr --> 1x192 les últimes 192 mostres de irradiació (corresponents a 48 hores amb un període de 15 minuts) en kW/m2
- cons --> 1x192 les últimes 192 mostres de consum (corresponents a 48 hores amb T de 15 minuts) en kW

**Outputs**

- pred\_def --> 1x96, predicció de les pròximes 96 mostres (24 hores) del dèficit [kW]
- pred\_irr--> 1x96, predicció de les pròximes 96 mostres (24 hores) d'irradiació [kW/m2]
- pred\_cons--> 1x96, predicció de les pròximes 96 mostres (24 hores) del consum [kW]

**irr\_net.m i cons\_net.m:** Són les dues xarxes que componen el model. Per utilitzar-les cal crear els vectors d'entrada correctament. La funció `model_final.m` inclou aquesta adaptació, i crida posteriorment a les xarxes i retorna les prediccions corresponents. Per tant, encara que només es vulgui obtenir, per exemple, la predicció d'irradiació, es recomana utilitzar directament la funció `model_final`

**def\_net.m:** Es tracta de la xarxa que inclou el model conjunt d'irradiació i consum per predir el dèficit. Com s'explica a la memòria, el resultat resulta menys precís que el cas de `model_final.m`

**Carpeta "Dades":** Inclou el fitxer amb les dades que es van obtenir per l'etapa 4, sense realitzar cap modificació. Les dades de les etapes 1, 2 i 3 ocuparien massa espai per a ser incloses. Es poden obtenir seguint els enllaços [20] i [21] de la Bibliografia.

**Carpeta "Model teòric":** Inclou els fitxers de Matlab donats per l'Andreu Cecilia amb el model teòric del càlcul d'irradiació solar [26]. ". Dins la carpeta hi ha un `READ_ME` específic per a l'ús d'aquest model.



## Altres

Figura 3.48 en més detall

